



Entwicklerhandbuch für Amazon Nova 2

Amazon Nova



Amazon Nova: Entwicklerhandbuch für Amazon Nova 2

Copyright © 2026 Amazon Web Services, Inc. and/or its affiliates. All rights reserved.

Die Handelsmarken und die Handelsaufmachung von Amazon dürfen nicht in einer Weise in Verbindung mit nicht von Amazon stammenden Produkten oder Services verwendet werden, durch die Kunden irregeführt werden könnten oder Amazon in schlechtem Licht dargestellt oder diskreditiert werden könnte. Alle anderen Handelsmarken, die nicht Eigentum von Amazon sind, gehören den jeweiligen Besitzern, die möglicherweise zu Amazon gehören oder nicht, mit Amazon verbunden sind oder von Amazon gesponsert werden.

Table of Contents

Was ist Amazon Nova 2?	1
Die wichtigsten Konzepte	1
Amazon Nova-Modelle	2
Was kannst du bauen?	2
Vorteile	3
So funktioniert Amazon Nova	3
Preisgestaltung	4
Nächste Schritte	4
Was ist neu in Amazon Nova 2	5
Neue -Modelle	5
Neue Funktionen und Fähigkeiten	5
Nova Multimodale Einbettungen	5
Erweitertes Denken und Argumentieren	5
Integrierte Tools	6
Erstellung von KI-Agenten	6
Verbessertes Verständnis von Dokumenten	6
Verbessertes Verständnis von Videos	6
Modellanpassung	6
Amazon Nova Forge	7
Nächste Schritte	7
Erste Schritte	8
Erste Schritte in der Konsole	8
Kennenlernen des Text-Playgrounds	9
Erste Schritte mit der -API	9
Einholen von Anmeldeinformationen, um programmgesteuerten Zugriff zu gewähren	11
Anfügen von Amazon-Bedrock-Berechtigungen an einen Benutzer oder eine Rolle	13
Eine Antwort auf einen Text-Prompt mithilfe eines Amazon-Nova-Modells generieren	14
Kernschlussfolgerung	15
Wichtig: Timeout-Konfiguration	16
Kernthemen der Inferenz	16
Verwendung der Converse-API	17
Struktur der Anfrage	17
Verwenden von Systemaufforderungen	18
Inferenzparameter	19

Argumentation verwenden	20
Verwenden der Invoke-API	23
Struktur der Anfrage	23
Anforderungsparameter	24
Streaming-Antworten	24
Streamen mit ConverseStream	24
Streamen mit InvokeModelWithResponseStream	25
Ereignistypen streamen	26
Verwenden von Amazon Nova-Einbettungen	26
Schlüssel-Features	27
Einbettungen werden generiert	27
On-Demand-Inferenz	31
Vorteile	31
Verwendung von On-Demand-Inferenz	31
Preisgestaltung	32
Kontingente und -Einschränkungen	32
Nutzung der Nova-Funktionen	33
Reasoning	33
Multimodales Verständnis	34
Unterstützter Inhaltstyp nach Modalität	34
Bildverständnis	35
Video-Verständnis	37
Verstehen von Dokumenten	40
Speech-to-Speech	43
Schlüssel-Features	43
Erste Schritte	44
Importe und Konfiguration angeben	44
Definieren der SimpleNovaSonic-Klasse	45
Initialisieren des -Client	46
Behandlung von Ereignissen	46
Die Sitzung starten	47
Behandlung der Audioeingabe	49
Beenden der Sitzung	51
Umgang mit Antworten	52
Audio wiedergeben	53
Audio aufnehmen	54

Die Hauptfunktion ausführen	55
Codebeispiele	56
Erste Schritte, Beispiele	56
Fortgeschrittene Anwendungsfälle	57
Hands-on Werkstatt	58
Eingabeaufforderungen für Sprachgespräche	58
Wichtige Richtlinien	59
Empfohlene Standard-Systemaufforderung für Spracheingabe	59
Konfiguration der Sprachaufforderung	59
Konfiguration der Systemaufforderung	60
Geschlechtervereinbarung für geschlechtsspezifische Sprachen	61
Gedankenkette für Speech: Verfassungsrechtliche Argumentation	62
Übermäßiger Gebrauch von vorgeschlagenen Ausdrücken	63
Schlüsselkonzepte	65
Lebenszyklus eines Ereignisses	65
Reihenfolge des Ablaufs der Ereignisse	67
Behandlung von Eingabeereignissen mit der bidirektionalen API	67
Ausgabeereignisse mit der bidirektionalen API behandeln	76
Barge-in	83
Turn-taking Steuerbarkeit	85
Cross-modal Eingabe	86
Sprachunterstützung und mehrsprachige Funktionen	89
Verwaltung des Chat-Verlaufs	91
Konfiguration des Tools	98
Asynchroner Werkzeugaufruf	105
Integrationen	108
Strands, Agenten	108
Framework-Integrationen	111
Fortschrittliche Systeme mit Nova	122
-Übersicht	122
Erweitertes Denken	122
So funktioniert erweitertes Denken	122
Konfigurationsoptionen	125
Unterstützte Modelle	126
Erweitertes Denken mit der Verwendung des Tools	126
Grundlegendes zu Argumentation, Tokens und Preisgestaltung	127

Häufig gestellte Fragen	127
Verwendung des Tools	128
Grundlegendes zum Arbeitsablauf bei der Verwendung von Tools	128
Erstellen Sie ein Tool	129
Rufen Sie ein Tool auf	132
Integrierte Systemtools	136
KI-Agenten erstellen	138
Erstellen eines Agenten	138
Aufrufen eines Agenten	140
Web Grounding	143
Wie funktioniert Web Grounding	143
Web Grounding verwenden	144
Regionale Verfügbarkeit	145
Struktur der Antworten	145
Sicherheit bei der Erdung	146
Fehlerbehandlung	146
Für integrierte Tools sind Berechtigungen erforderlich	147
Prompt-Engineering	149
Was ist Prompt Engineering	149
Erste Schritte mit Prompt Engineering	149
Best Practices	150
Die Rollen verstehen	150
Erstellen Sie präzise Eingabeaufforderungen	151
Den Fokus auf Abschnitte des Prompts legen	170
Die Systemrolle verwenden	171
Geben Sie Beispiele (Few-Shot-Prompting)	180
Systeme zum Aufrufen von Tools	190
Fortgeschrittene Aufforderungstechniken	191
Aufforderung zu multimodalen Eingaben	213
Allgemeine multimodale Richtlinien	214
Verständnis von Dokumenten und Bildern	215
Video-Verständnis	37
Moderation von Inhalten	226
Die wichtigsten Prinzipien	227
Empfohlene Konfiguration	227
MLCommons universelle Taxonomie	227

Anregende Beispiele	229
Anwendungsfälle für Sicherheit	235
Die wichtigsten Prinzipien	235
Planer zur Jagd nach Bedrohungsdaten	235
Code und Problembehebung	244
Code-Bibliothek	244
Beispiele für die Converse API	244
InvokeModel API-Beispiele	264
Fehlerbehebung	269
Authentifizierung und Einrichtung	269
Modellzugriff verweigert	270
Probleme mit der regionalen Verfügbarkeit	270
Timeout-Konfiguration	270
Probleme mit der API-Antwort	271
Fehler im Argumentationsmodus	272
Probleme bei der Verwendung von Tools	273
API- und SDK-Referenz	277
Anfrage- und Antwortschema	277
Vollständige Anforderungsstruktur	277
Vollständige Antwortstruktur	282
SDK-Referenz	285
Anpassung des Amazon Nova-Modells	287
Ansätze zur Anpassung	287
Plattformen zur Anpassung	288
Allgemeine Voraussetzungen	289
Amazon-Nova-Rezepte	290
Erstellen von Basisrezepten	291
Forge-Rezepte abrufen	291
Verfügbare Modelle und Algorithmen	292
Amazon Nova 2.0 Lite	293
Bei SageMaker Ausbildungsjobs	299
Bewährte Methoden für die Anpassung von Amazon Nova	299
Nova Forge SDK	305
Training	312
Überwachung des Fortschritts zwischen den Iterationen	368
Bewertung	373

Iteratives Training	443
An SageMaker HyperPod	444
Rechenanforderungen für Amazon Nova 2-Modelle	444
Bewährte Methoden für die Anpassung von Amazon Nova	299
Nova Forge SDK	451
HP-Cluster-Setup	452
Leitfaden zu den wichtigsten Befehlen	452
Zugang und Einrichtung von Nova Forge	463
Training	464
Bewertung	507
MLflow-Überwachung	561
Iteratives Training	564
-Übersicht	564
Funktionsweise	565
Wann sollte iteratives Training verwendet werden	566
Beispiel-Workflow: SFT → RFT	568
Überwachung des Fortschritts zwischen den Iterationen	569
Best Practices	572
Kostenüberlegungen	574
Einschränkungen	574
Fehlerbehebung	576
Modell zusammenführen	577
Anwendbarkeit nach Schulungstyp	578
Wann sollte das Zusammenführen von Modellen verwendet werden	578
Wie konfiguriert man Gewichte für das Zusammenführen von Modellen	579
Auswahl des Modells Gewichte zusammenführen	580
Bewertung Ihres Merge-Gewichts	581
So funktioniert das Zusammenführen: Feinabstimmung Full-rank	582
So funktioniert das Zusammenführen: LoRa-Feinabstimmung	582
SageMaker Folgerung	583
Features	584
Unterstützte Modelle und Instanzen	585
Inferenzkomponenten	589
Unterstützt AWS Regionen	590
Unterstützte Container-Images	590
Bewährte Methoden	590

Support	591
Erste Schritte	591
Funktionen des Containers	617
API-Referenz	631
Missbrauchserkennung für Amazon Nova Forge	641
Amazon-Bedrock-Inferenz	642
Ein benutzerdefiniertes Modell für On-Demand-Inferenz bereitstellen	643
On-demand Inferenz	649
Einschränkungen	650
Bewertung mit Inspect AI	651
Untersuchen Sie das AI SDK	652
Untersuchen Sie den KI-Container	659
Nova Forge	689
Voraussetzungen	689
Abonnieren Sie Nova Forge	689
Andere Voraussetzungen	690
Zugang und Einrichtung von Nova Forge	690
Abrufen der Nova Forge-Dokumente	690
Schritt 1: Abonnieren Sie Nova Forge	691
Schritt 2. HyperPod Infrastruktur einrichten	697
Einstellungen für die Inhaltsmoderation	697
Fortsetzung und Pre-Training Mid-Training	698
Was sind Zwischenkontrollpunkte und warum werden sie benötigt?	698
Welche Checkpoints sind verfügbar?	699
Welcher Checkpoint soll verwendet werden?	700
Wie verwendet man das Mischen von Daten für Nova 2.0?	701
Analyse der Datenmischungskategorien	703
Senken Sie die Speicherkosten, indem Sie Trainingsdaten von Amazon S3 streamen	707
Betreut Fine-Tuning	710
Datenmischung an SageMaker HyperPod	710
Mischen von Daten bei SageMaker Trainingsjobs	736
Reinforcement Learning	749
Verwenden Sie Ihren eigenen Orchestrator für behördliche Multi-Turn-Evaluierungen	750
Verantwortliches KI-Toolkit	751
Toolkit für verantwortungsvolle KI	751
Verfügbarkeit in Regionen	752

Verantwortungsvolle Verwendung	754
Richtlinien	754
Empfehlungen	755
Kontingente	757
Eine Erhöhung der Amazon-Nova-Kontingente beantragen	757
Überwachen	759
Sicherheit	760
Erstellen Sie Ressourcen mit CloudFormation	761
Erfahren Sie mehr über CloudFormation	761
Dokumentverlauf	762
.....	dcclxiii

Was ist Amazon Nova 2?

Amazon Nova bietet multimodale Basismodelle, die Text, Bilder, Videos, Dokumente und Sprache verarbeiten. Mit Unterstützung für bis zu 1 Million Kontext-Token und erweiterten Argumentationsfunktionen ermöglichen Ihnen die Amazon Nova 2-Modelle die Entwicklung ausgeklügelter KI-Anwendungen, die komplexe Eingaben verstehen und genaue Antworten generieren.

Sie können interaktive Chatbots erstellen, Dokumente und Videos analysieren, KI-Agenten mit erweiterter Argumentation einrichten und sprachgesteuerte Anwendungen entwickeln.

Die wichtigsten Konzepte

Machen Sie sich mit den folgenden Kernkonzepten vertraut, bevor Sie sich mit den Amazon Nova-Modellen vertraut machen:

Fundament-Modelle

Pre-trained KI-Systeme, die in verschiedenen Größen und Funktionen erhältlich sind und auf die Sie über eine API zugreifen können.

Inferenz

Der Prozess des Sendens einer Anfrage an ein Modell und des Empfangens einer generierten Antwort.

Argumentation

Erweiterte Denkfähigkeit, die es Modellen ermöglicht, komplexe Probleme aufzuschlüsseln und ihre Analyse Schritt für Schritt nachzuweisen, bevor sie Antworten liefern.

Multimodal

Die Fähigkeit, mehrere Eingabearten zusammen zu verarbeiten und zu verstehen: Text, Bilder, Video und Dokumente in einer einzigen Anfrage.

RAG (Retrieval-Augmented Generation)

Eine Technik, bei der Modellantworten mit Ihren eigenen Datenquellen kombiniert werden, um genauere, kontextbezogene Antworten zu erhalten.

Amazon Nova-Modelle

Amazon Nova 2 umfasst die folgenden Modelle, die jeweils für unterschiedliche Anwendungsfälle optimiert sind:

Modell	Eingabemodalitäten	Ausgabemodalitäten	Anwendungsfälle
Nova 2 Lite	Text, Bilder, Videos, Dokumente	Text	High-volume Anwendungen, bei denen Geschwindigkeit und Kosteneffizienz im Vordergrund stehen
Nova 2 Sonic	Sprache, Text	Sprache, Text	Voice-enabled Anwendungen mit schnellen Reaktionszeiten
Nova Multimodale Einbettungen	Text, Bilder, Dokumente, Video, Audio	Einbettungen	Semantische Suche, Empfehlungssysteme und Ähnlichkeitsabgleich

Alle Modelle unterstützen bis zu 1 Million Kontext-Token und können mit einer einzigen Antwort bis zu 65.536 Token generieren. Modelle mit Argumentationsfähigkeiten können durch erweitertes Denken komplexe Probleme Schritt für Schritt lösen.

Was kannst du bauen?

Im Folgenden finden Sie Beispiele dafür, was Sie mit Amazon Nova erstellen können:

- Intelligenter Dokumentenassistent — Verarbeiten Sie große Dokumente mit bis zu 1 Million Kontext-Tokens, um Fragen zu beantworten und Erkenntnisse zu gewinnen (mit RAG)
- Anwendungen zur komplexen Argumentation — Lösen Sie Probleme in mehreren Schritten mit erweitertem Denken, das die schrittweise Analyse des Modells zeigt (oder mit Argumentation)

- Videoanalyse-Pipeline — Extrahieren Sie Erkenntnisse, erstellen Sie Zusammenfassungen und identifizieren Sie wichtige Momente in Videoinhalten in großem Maßstab (Nova 2 Lite)
- Voice-enabled KI-Agent — Entwickeln Sie Konversationsagenten, die Spracheingaben verstehen und mit natürlicher Sprache reagieren (Nova 2 Sonic)

Vorteile

Amazon Nova bietet die folgenden Vorteile:

Multimodales Verständnis

Verarbeiten Sie Text, Bilder, Videos, Dokumente und Sprache in einer einzigen Anfrage. Amazon Nova-Modelle verstehen Beziehungen zwischen verschiedenen Eingabearten.

Erweiterter Kontext

Durch die Support von bis zu 1 Million Tokens können Sie ganze Codebasen, umfangreiche Dokumente oder ausgedehnte Konversationen verarbeiten, ohne den Kontext zu verlieren.

Argumentation für Fortgeschrittene

Modelle mit Argumentationsfähigkeiten lösen komplexe Probleme auf und zeigen eine schrittweise Analyse, wodurch die Genauigkeit bei mehrstufigen Aufgaben verbessert wird.

Flexibler Einsatz

Greifen Sie über Amazon Bedrock auf Modelle zu, ohne dass eine Infrastruktur verwaltet werden muss, oder passen Sie Modelle durch Feinabstimmung und Reinforcement-Learning an.

Built-in Werkzeuge

Verwenden Sie Web Grounding, um auf Echtzeitinformationen und einen Codeinterpreter zuzugreifen, um Python-Code ohne externe Integrationen auszuführen.

So funktioniert Amazon Nova

Amazon Nova-Modelle sind Basismodelle, auf die Sie über Amazon Bedrock zugreifen. Der grundlegende Arbeitsablauf ist:

1. Ihre Anwendung sendet eine Anfrage mit Ihren Eingabe- und Konfigurationsparametern an Amazon Bedrock.

2. Das Amazon Nova-Modell verarbeitet Ihre Eingaben und wendet, falls konfiguriert, Argumentation an.
3. Das Modell generiert eine Antwort und sendet sie an Ihre Anwendung zurück.

Sie können die Antworten verbessern, indem Sie Ihre Daten mit RAG integrieren, integrierte Tools aktivieren oder Modelle durch Feinabstimmung anpassen.

Preisgestaltung

Die Preise von Amazon Nova basieren auf den verarbeiteten Eingabe- und Ausgabetokens. Verschiedene Modelle haben unterschiedliche Preisstufen:

- Nova 2 Lite — Optimierte für die kostengünstige Verarbeitung großer Mengen
- Nova 2 Sonic — Ausgewogene Preisgestaltung für sprachgesteuerte Anwendungen

Aktuelle Preisinformationen finden Sie unter [Amazon Bedrock Pricing](#).

Nächste Schritte

- Weitere Informationen zu den neuen Funktionen in Amazon Nova 2 finden Sie unter [Was ist neu in Amazon Nova 2](#).
- Informationen zum Einstieg in die Nutzung von Amazon Nova finden Sie unter [Erste Schritte mit Amazon Nova 2](#).
- Weitere Informationen zu den wichtigsten Inferenzfunktionen finden Sie unter [Kernschlussfolgerung](#).
- Informationen zum Anpassen von Modellen für Ihren Anwendungsfall finden Sie unter [Anpassen von Amazon Nova-Modellen auf KI SageMaker](#).

Was ist neu in Amazon Nova 2

Amazon Nova 2 bietet erhebliche Verbesserungen in den Bereichen Verständnis, Kreativität und Sprache. In den folgenden Abschnitten werden die wichtigsten neuen Funktionen und Verbesserungen beschrieben.

Neue -Modelle

Nova 2 Lite

Verbesserte Modelle, die fortgeschrittenes Denken mit erweiterter Denkkunterstützung, dreistufiger Intensitätssteuerung und multimodalem Verständnis bieten und für agentische Arbeitsabläufe im Produktionsmaßstab optimiert sind.

Nova 2 Sonic

Ein verbessertes Konversationssprachmodell mit verbessertem Sprachverständnis, natürlicher Sprachverarbeitung und Sprachgenerierung in sieben Sprachen.

Nova Multimodale Einbettungen

Ein multimodales Einbettungsmodell, das Text-, Bild-, Dokument-, Video- und Audioeingaben verarbeitet und Einbettungen generiert.

Neue Funktionen und Fähigkeiten

Nova Multimodale Einbettungen

Nova Multimodal Embeddings unterstützt Text, Dokumente, Bilder, Video und Audio über ein einziges Modell und ermöglicht so modalübergreifende Abrufanwendungen. Nova Multimodal Embeddings ordnet jeden dieser Inhaltstypen einem einheitlichen semantischen Raum zu, sodass Sie unimodale, modalübergreifende und multimodale Vektoroperationen durchführen können, die Anwendungen wie die agentische Retrieval-Augmented Generation (RAG) und die multimodale semantische Suche unterstützen.

Erweitertes Denken und Argumentieren

Nova 2 Lite unterstützt erweitertes Denken, sodass die Modelle mehr Zeit damit verbringen können, komplexe Probleme zu durchdenken, bevor sie Antworten generieren. Diese Funktion

verbessert die Genauigkeit bei Argumentationsaufgaben in mehreren Schritten, einschließlich agentischer Workflows mit mehreren Tools, fortgeschrittener Mathematik, komplexer Planung und Codegenerierung.

Um mehr zu erfahren, navigieren Sie zu. [Erweitertes Denken in Amazon Nova 2](#)

Integrierte Tools

Amazon Nova 2 enthält integrierte Tools, die die Modellfunktionen erweitern, ohne dass externe Integrationen erforderlich sind:

- Web Grounding — Greift auf Echtzeitinformationen aus dem Internet zu, um up-to-date Antworten zu geben und Halluzinationen zu reduzieren.
- Codeinterpreter — Führt Python-Code aus, um Berechnungen durchzuführen.

Erstellung von KI-Agenten

Die Modelle von Amazon Nova 2 sind für die Erstellung von KI-Agenten optimiert. Die Modelle bieten eine verbesserte Nutzung der Tools, eine bessere Argumentation für mehrstufige Aufgaben und eine verbesserte Fähigkeit, den Kontext in komplexen Agenten-Workflows aufrechtzuerhalten.

Verbessertes Verständnis von Dokumenten

Nova 2 Lite bietet erweiterte Funktionen zur Dokumentenverarbeitung mit einem besseren Verständnis komplexer Dokumentenlayouts, Tabellen, Diagramme und mehrseitiger Dokumente. Die Modelle extrahieren Informationen genauer aus PDFs, Tabellenkalkulationen und anderen Dokumentenformaten.

Verbessertes Verständnis von Videos

Nova 2 Lite bietet verbesserte Videoanalysefunktionen, einschließlich besserer visueller Wahrnehmung, zeitlichem Verständnis, Aktionserkennung und der Fähigkeit, längere Videosequenzen mit höherer Genauigkeit zu verarbeiten.

Modellanpassung

Nova 2 Lite unterstützt Supervised Fine-Tuning (SFT) und Reinforcement Fine-Tuning (RFT) auf Amazon Bedrock und SageMaker KI, sodass Sie Amazon Nova 2 an Ihre spezifischen Geschäftsanforderungen anpassen können.

Amazon Nova Forge

Amazon Nova Forge ist ein first-of-its-kind Service, der Unternehmen die einfachste und kostengünstigste Möglichkeit bietet, mithilfe von Amazon Nova ihre eigenen Grenzmodelle zu erstellen.

Nächste Schritte

- Weitere Informationen zu den Modellen und Funktionen von Amazon Nova finden Sie unter [Was ist Amazon Nova 2?](#).
- Informationen zum Einstieg in die Nutzung von Amazon Nova 2.0 finden Sie unter [Erste Schritte mit Amazon Nova 2](#).
- Informationen zu den wichtigsten Inferenzfunktionen finden Sie unter [Kernschlussfolgerung](#).

Erste Schritte mit Amazon Nova 2

Sie können Amazon Nova 2-Modelle mit den folgenden Methoden aufrufen:

- API-Operationen von Amazon Bedrock [InvokeModel](#) oder [Converse](#)
- Amazon Bedrock [Chat- und Textspielplätze](#) für Nova 2 Lite, Nova 2 Sonic

Important

Wenn Sie Amazon Bedrock AWS noch nicht kennen, müssen Sie zunächst Amazon Bedrock einrichten, indem Sie den Schritten unter [Erste Schritte mit Amazon Bedrock](#) folgen. [Alternativ können Sie die Amazon Nova-Modelle testen, ohne Amazon Bedrock auf nova.amazon.com aufrufen zu müssen, oder auf nova.amazon kostenlos mit dem Bauen beginnen. com/dev.](#)

Wählen Sie ein Thema aus, um die Verwendung von Amazon Nova mit dieser Methode zu beginnen.

Erste Schritte mit Amazon Nova in der Amazon-Bedrock-Konsole

In diesem Abschnitt wird beschrieben, wie Sie die Playgrounds in der AWS Konsole verwenden, um eine Textanfrage an Amazon Nova 2-Modelle zu senden und eine Text- oder Bildantwort zu generieren. Bevor Sie die folgenden Beispiele ausführen, sollten Sie sich vergewissern, dass Sie die folgenden Voraussetzungen erfüllt haben:

Voraussetzungen

- Sie haben ein AWS Konto und verfügen über die erforderlichen Berechtigungen für den Zugriff auf eine Rolle in diesem Konto mit den erforderlichen Berechtigungen für Amazon Bedrock. Folgen Sie andernfalls den Schritten unter [Erste Schritte mit Amazon Bedrock](#).
- Wenn Sie von einer US-Region aus auf das Modell zugreifen, müssen Sie den US-CRIS-Endpunkt verwenden. Dazu müssen Sie der Modell-ID das us Präfix hinzufügen (z. B. `us.amazon.nova-2-lite-v1:0`).
- Wenn Sie von außerhalb der USA auf das Modell zugreifen, können Sie entweder den globalen CRIS-Endpunkt (z. B. `global.amazon.nova-2-lite-v1:0`) verwenden oder der Region in der Modell-ID ein Präfix voranstellen (z. B. `us/eu/jp`).

Kennenlernen des Text-Playgrounds

Das folgende Beispiel zeigt, wie der Text-Playground verwendet wird:

1. Öffnen Sie die Amazon Bedrock-Konsole unter <https://console.aws.amazon.com/bedrock/>.
2. Wählen Sie im linken Navigationsbereich unter Playgrounds die Option Chat/Text aus.
3. Wählen Sie Modell auswählen und wählen Sie einen Anbieter und ein Modell aus. Wählen Sie für dieses Beispiel Amazon und dann ein Amazon Nova 2-Modell (wie Nova 2 Lite oder Nova 2 Sonic) aus. Wählen Sie dann Apply (Anwenden).
4. Wählen Sie einen Standard-Prompt unter dem Textbereich aus, oder geben Sie einen Prompt in das Textfeld ein, z. B. **Describe the purpose of a "hello world" program in one line.**
5. Um die Fähigkeiten von Amazon Nova im Bereich der Bilderkennung zu erkunden, können Sie ein Bild im JPEG-, PNG-, GIF- oder WEBP-Format mit einer Größe von maximal 25 MB von Ihrem Computer hochladen. Nachdem das Bild hochgeladen wurde, können Sie Amazon Nova zu dem Bild befragen.
6. Um die Funktionen von Amazon Nova zum Verstehen von Dokumenten zu erkunden, können Sie Dokumente im CSV-, DOC-, DOCX-, HTML-, MD-, PDF-, TXT-, XLS- oder XLSX-Format hochladen, die kleiner oder gleich 4,5 MB sind. Nachdem die Dokumente hochgeladen wurden, können Sie Amazon Nova zu den Dokumenten befragen.
7. Um die Fähigkeiten von Amazon Nova im Bereich der Videoerkennung zu erkunden, können Sie ein Video im MKV, MOV oder MP4-Format mit einer Größe von maximal 25 MB von Ihrem Computer hochladen. Sie können Amazon S3 für Videos mit bis zu 1 GB verwenden. Nachdem das Video hochgeladen wurde, können Sie Amazon Nova zu dem Video befragen.
8. Wählen Sie Ausführen, um die Inferenz für das Modell auszuführen. Der generierte Text wird unter Ihrem Prompt im Textfeld angezeigt.

Erste Schritte mit der -API

Bevor Sie mit APIs beginnen, folgen Sie diesen Verfahren, wenn Sie mit der AWS CLI AWS oder einem AWS SDK noch nicht vertraut sind oder diese installieren müssen. Wenn keine dieser Optionen auf Sie zutrifft, wechseln Sie zu [Einholen von Anmeldeinformationen, um programmgesteuerten Zugriff zu gewähren](#).

Ich bin neu bei AWS

Wenn Sie noch kein AWS Konto haben, führen Sie die folgenden Schritte aus, um eines zu erstellen. Alternativ können Sie mit dem kostenlosen Bauen mit Amazon Nova unter nova.amazon.com/dev.

Um sich für eine anzumelden AWS Konto

1. Öffnen Sie <https://portal.aws.amazon.com/billing/signup>.
2. Folgen Sie den Online-Anweisungen.

Während der Anmeldung erhalten Sie einen Telefonanruf oder eine Textnachricht und müssen einen Verifizierungscode über die Telefontasten eingeben.

Wenn Sie sich für ein AWS Konto registrieren, wird ein Root-Benutzer für das AWS Konto erstellt. Der Root-Benutzer hat Zugriff auf alle AWS -Services und -Ressourcen des Kontos. Aus Sicherheitsgründen sollten Sie einem Benutzer Administratorzugriff zuweisen und nur den Root-Benutzer verwenden, um [Aufgaben auszuführen, für die Root-Benutzerzugriff erforderlich](#) ist.

AWS sendet Ihnen nach Abschluss des Anmeldevorgangs eine Bestätigungs-E-Mail. Sie können jederzeit Ihre aktuelle Kontoaktivität ansehen und Ihr Konto verwalten. Rufen Sie dazu <https://aws.amazon.com/> auf und klicken Sie auf Mein Konto.

Sichern Sie sich Ihre AWS Stammbenutzer des Kontos

1. Melden Sie sich [AWS-Managementkonsole](#) als Kontoinhaber an, indem Sie Root-Benutzer auswählen und die E-Mail-Adresse Ihres AWS Kontos eingeben. Geben Sie auf der nächsten Seite Ihr Passwort ein.

Hilfe bei der Anmeldung mit dem Root-Benutzer finden Sie unter [Anmelden als Root-Benutzer](#) im AWS Sign-In-Benutzerhandbuch zu.

2. Aktivieren Sie die Multi-Faktor-Authentifizierung (MFA) für den Root-Benutzer.

Anweisungen finden Sie unter [Aktivieren eines virtuellen MFA-Geräts für den Root-Benutzer \(Konsole\) Ihres AWS Kontos](#) im IAM-Benutzerhandbuch.

Ich muss das installieren AWS CLI oder ein AWS SDK

Um die AWS CLI zu installieren, folgen Sie den Schritten unter [Installation oder Aktualisierung auf die neueste Version der AWS CLI](#).

Um ein AWS SDK zu installieren, wählen Sie unter [Tools to Build on die Registerkarte aus, die der Programmiersprache entspricht](#), die Sie verwenden möchten AWS.

AWS Software Development Kits (SDKs) sind für viele gängige Programmiersprachen verfügbar. Jedes SDK bietet eine API, Codebeispiele und Dokumentation, die es Entwicklern erleichtern, Anwendungen in ihrer bevorzugten Sprache zu erstellen. SDKs erledigen automatisch nützliche Aufgaben für Sie, zum Beispiel:

- Kryptographisches Signieren Ihrer Serviceanforderungen
- Wiederholungsanforderungen
- Umgang mit Fehlerantworten

Einholen von Anmeldeinformationen, um programmgesteuerten Zugriff zu gewähren

Benutzer benötigen programmgesteuerten Zugriff, wenn sie AWS außerhalb der AWS Management Console interagieren möchten. Die Art und Weise, wie der programmgesteuerte Zugriff gewährt wird, hängt von der Art des Benutzers ab, der zugreift. AWS

Um Benutzern programmgesteuerten Zugriff zu gewähren, wählen Sie eine der folgenden Optionen.

Welcher Prinzipal benötigt programmgesteuerten Zugriff?	Bis	Von
IAM-Benutzer	Beschränken Sie die Dauer langfristiger Anmeldeinformationen, um programmatische Anfragen an die AWS CLI, AWS SDKs oder AWS APIs zu signieren.	Befolgen Sie die Anweisungen für die Schnittstelle, die Sie verwenden möchten. • Informationen zur AWS CLI finden Sie unter Authentifizierung mithilfe

Welcher Prinzipal benötigt programmgesteuerten Zugriff?	Bis	Von
		von IAM-Benutzeranmeldedaten im Benutzerhandbuch für die AWS Befehlszeilenschnittstelle. • Informationen zu AWS SDKs und Tools finden Sie unter Authentifizieren mit langfristigen Anmeldeinformationen im Referenzhandbuch für AWS SDKs und Tools. • Informationen zu AWS APIs finden Sie unter Verwaltung von Zugriffsschlüsseln für IAM-Benutzer im IAM-Benutzerhandbuch.
IAM-Rollen	Verwenden Sie temporäre Anmeldeinformationen, um programmatische Anfragen an die AWS CLI, AWS SDKs oder AWS APIs zu signieren.	Folgen Sie den Anweisungen unter Verwenden temporärer Anmeldeinformationen mit AWS Ressourcen im IAM-Benutzerhandbuch.

Welcher Prinzipal benötigt programmgesteuerten Zugriff?	Bis	Von
Im IAM Identity Center verwaltete Benutzer	Verwenden Sie temporäre Anmeldeinformationen, um programmatische Anfragen an die AWS CLI, AWS SDKs oder AWS APIs zu signieren.	Befolgen Sie die Anweisungen für die Schnittstelle, die Sie verwenden möchten. • Informationen zur AWS CLI finden Sie unter Konfiguration der AWS CLI für die Verwendung von IAM Identity Center im Benutzerhandbuch für die AWS Befehlszeilenschnittstelle. • Informationen zu AWS SDKs, Tools und AWS APIs finden Sie unter IAM Identity Center-Authentifizierung im Referenzhandbuch für AWS SDKs und Tools.

Anfügen von Amazon-Bedrock-Berechtigungen an einen Benutzer oder eine Rolle

Nachdem Sie die Anmeldeinformationen für den programmatischen Zugriff eingerichtet haben, müssen Sie die Berechtigungen für einen Benutzer oder eine IAM-Rolle konfigurieren, um Zugriff auf Bedrock-related Amazon-Aktionen zu erhalten. Gehen Sie folgendermaßen vor, um diese Berechtigungen einzurichten:

1. Wählen Sie auf der Startseite der AWS Management Console den IAM-Service aus oder navigieren Sie zur IAM-Konsole unter. <https://console.aws.amazon.com/iam/>
2. Wählen Sie Benutzer oder Rollen und dann Ihren Benutzer oder Ihre Rolle aus.
3. Wählen Sie auf der Registerkarte „Berechtigungen“ die Option „Berechtigungen hinzufügen“ und anschließend „AWS Verwaltete Richtlinie hinzufügen“ aus. Wählen Sie die verwaltete [AmazonBedrockFullAccess](#) AWS -Richtlinie.

4. Um dem Benutzer oder der Rolle das Abonnieren von Modellen zu ermöglichen, wählen Sie Inline-Richtlinie erstellen und geben Sie dann die folgenden Berechtigungen im JSON-Editor an:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "MarketplaceBedrock",
      "Effect": "Allow",
      "Action": [
        "aws-marketplace:ViewSubscriptions",
        "aws-marketplace:Unsubscribe",
        "aws-marketplace:Subscribe"
      ],
      "Resource": "*"
    }
  ]
}
```

Eine Antwort auf einen Text-Prompt mithilfe eines Amazon-Nova-Modells generieren

Nachdem Sie alle Voraussetzungen erfüllt haben, können Sie das Erstellen von Modellaufrufanforderungen an Amazon Nova-Modelle mit einer [Converse-Anfrage](#) testen.

Um die AWS CLI zu installieren, folgen Sie den Schritten unter [Installation oder Aktualisierung auf die neueste Version der AWS CLI](#). Überprüfen Sie, ob Sie Ihre Anmeldeinformationen für die Verwendung von Boto3 gemäß den Schritten unter [Einholen von Anmeldeinformationen, um programmgesteuerten Zugriff zu gewähren](#) konfiguriert haben.

Um eine Antwort auf eine Textaufforderung in Nova 2 Lite mithilfe der AWS CLI zu generieren, führen Sie den folgenden Befehl in einem Terminal aus:

```
aws bedrock-runtime converse \
  --model-id us.amazon.nova-2-lite-v1:0 \
  --messages '[{"role":"user","content":[{"text":"Write a short poem"}]]' \
  --additional-model-request-fields '{"reasoningConfig":
{"type":"enabled","maxReasoningEffort":"low"}}'
```


Kernschlussfolgerung

Inferenz ist der Prozess, bei dem eine Anfrage an ein Amazon Nova-Modell gesendet und eine generierte Antwort empfangen wird. Amazon Nova-Modelle unterstützen Inferenzen über zwei API-Optionen:

- Converse API ([Converse](#), [ConverseStream](#)): Bietet eine konsistente Schnittstelle für verschiedene Modelle, wodurch es einfacher wird, zwischen Modellen zu wechseln oder Anwendungen zu erstellen, die mit mehreren Modellen funktionieren. Für die meisten Anwendungsfälle empfohlen.
- API aufrufen ([InvokeModel](#), [InvokeModelWithResponseStream](#)): Anforderungs-Payloads sind speziell für das native Format jedes Modells strukturiert. Führt die Inferenz mithilfe der Eingabeaufforderung und der Inferenzparameter aus, die im Hauptteil der Anfrage bereitgestellt werden.

Beide APIs unterstützen dieselben Kernfunktionen, darunter:

- Multi-turn-Konversationen
- Multimodale Eingaben (Text, Bilder, Video, Audio)
- Verwendung des Tools
- Integritätsschutz
- Streaming-Antworten

Die Anforderungsstruktur ist zwischen den beiden nahezu identisch und unterscheidet sich nur darin APIs, wie Bytedaten (Dokumente, Bilder, Video und Audio) kodiert werden. Für Modellanforderungsparameter, die nur für Amazon Nova-Modelle gelten, wie `reasoningConfig` und `TopK`, werden diese in einem zusätzlichen `inferenceConfig` Objekt innerhalb von `additionalModelRequestFields` platziert. Dies sind Parameter der obersten Ebene für `InvokeModel` und `InvokeModelWithResponseStream`.

Note

Unter Codebeispiele und Problembehandlung finden Sie eine Liste der Codebeispiele für Nova 2-Modelle.

Stellen Sie den `modelId` Wert auf einen der folgenden Werte ein, um Amazon Nova-Modelle zu verwenden:

Modell	Modell-ID
Nova 2 Lite	• <code>global.amazon.nova-2-lite-v 1:0</code> • <code>us.amazon.nova-2-lite-v 1:0</code>
Nova 2 Sonic	• <code>global.amazon.nova-2-sonic-v 1:0</code> • <code>us.amazon.nova-2-sonic-v 1:0</code>
Nova Multimodale Einbettungen	<code>amazon.nova-2-1:0 multimodal-embeddings-v</code>

Wichtig: Timeout-Konfiguration

Important

Die Bearbeitung von Amazon Nova-Inferenzanfragen kann bis zu 60 Minuten dauern.

Konfigurieren Sie Ihre Client-Timeout-Einstellungen entsprechend:

Das folgende Beispiel ist Python-Code. Benutzer können in der Dokumentation zu ihrer bevorzugten SDK-Sprachversion in den API-Dokumenten des jeweiligen SDKS nachschauen.

```
from botocore.config import Config

bedrock = boto3.client(
    'bedrock-runtime',
    region_name='us-east-1',
    config=Config(
        read_timeout=3600 # 60 minutes
    )
)
```

Kernthemen der Inferenz

In diesem Abschnitt werden die folgenden Themen behandelt:

- Verwendung der Converse API: Eine konsistente Schnittstelle, die Kompatibilität mit den meisten Bedrock-Modellen bietet
- Verwendung der Aufruf-API: Eine Schnittstelle, die nur für Nova-Modelle verfügbar ist und nicht auf andere Bedrock-Modelle übertragbar ist
- Streaming-Antworten: Generierung von Antworten in Echtzeit
- Verwenden von Amazon Nova-Einbettungen: Funktionen zum Einbetten von Text
- Inferenz auf Abruf: Inferenzmodell Pay-per-use

Verwendung der Converse-API

Die Converse-API bietet eine einheitliche Schnittstelle für die Interaktion mit Amazon Nova-Modellen. Es abstrahiert modellspezifische Details und bietet eine konsistente Methode zur Verwaltung von Multi-Turn-Konversationen, Systemaufforderungen und Streaming-Antworten für alle Amazon Nova-Modelle.

Themen

- [Struktur der Anfrage](#)
- [Verwenden von Systemaufforderungen](#)
- [Inferenzparameter](#)
- [Argumentation verwenden](#)

Struktur der Anfrage

- Multi-Turn-Konversationen: Behalten Sie den Kontext über mehrere Börsen hinweg bei
- Systemaufforderungen: Systemanweisungen wie Personas oder Antwortrichtlinien
- Chat mit Dokumenten: Interagieren Sie mit Dokumenten oder Dokumentensammlungen und fragen Sie diese ab
- Vision: Bilder und Videos verarbeiten und analysieren
- Verwendung von Tools: Ermöglichen Sie Modellen die Verwendung externer Tools und APIs
- Leitplanken: Wenden Sie Inhaltsfilterung und Sicherheitskontrollen an
- Argumentation: Erweitertes Denken zur Lösung komplexer Probleme

Eine grundlegende Converse API-Anfrage enthält die Modell-ID und eine Liste von Nachrichten:

```
import boto3

bedrock = boto3.client('bedrock-runtime', region_name='us-east-1')

response = bedrock.converse(
    modelId='us.amazon.nova-2-lite-v1:0',
    messages=[
        {
            'role': 'user',
            'content': [{'text': 'What is machine learning?'}]
        }
    ]
)

content_list = response["output"]["message"]["content"]
# Extract the first text block
text = next((item["text"] for item in content_list if "text" in item), None)
if text is not None:
    print(text)
```

Verwenden von Systemaufforderungen

Systemaufforderungen bieten Kontext und Anweisungen für das Modell:

```
import boto3

bedrock = boto3.client('bedrock-runtime', region_name='us-east-1')

response = bedrock.converse(
    modelId='us.amazon.nova-2-lite-v1:0',
    system=[
        {'text': 'You are a helpful AI assistant specializing in cloud computing.'}
    ],
    messages=[
        {
            'role': 'user',
            'content': [{'text': 'Explain serverless computing.'}]
        }
    ]
)

# Print the response text
content_list = response["output"]["message"]["content"]
```

```
text = next((item["text"] for item in content_list if "text" in item), None)
if text is not None:
    print(text)
```

Inferenzparameter

Steuern Sie die Ausgabe des Modells mithilfe von Inferenzparametern. Die folgenden Inferenzparameter sind verfügbar.

- **maxTokens (Integer):** Maximale Anzahl der zu generierenden Token (bis zu 65.000). Wenn nicht angegeben, verwendet das Modell einen dynamischen Standard, der auf dem Anforderungskontext basiert.
- **Temperatur (Float):** Steuert die Zufälligkeit (0,0-1,0, Standard 0,7). Niedrigere Werte machen die Ausgabe deterministischer
- **toPP (float):** Nucleus-Abtastschwellenwert (0-1, Standard 0,9). Niedrigere Werte sorgen für eine zielgerichtete Ausgabe
- **stopSequences (Array):** Zeichenfolgen, die die Generierung beenden, wenn sie gefunden werden

Beispiel:

```
import boto3
bedrock = boto3.client('bedrock-runtime', region_name='us-east-1')

response = bedrock.converse(
    modelId='us.amazon.nova-2-lite-v1:0',
    messages=[
        {
            'role': 'user',
            'content': [{'text': 'Write a short story.'}]
        }
    ],
    inferenceConfig={
        'maxTokens': 512,
        'temperature': 0.7,
        'topP': 0.9,
        'stopSequences': ['END']
    }
)

content_list = response["output"]["message"]["content"]
```

```
text = next((item["text"] for item in content_list if "text" in item), None)
if text is not None:
    print(text)
```

Argumentation verwenden

Nova 2 Lite unterstützt erweitertes Denken zur Lösung komplexer Probleme. Ermöglichen Sie das Denken mit `reasoningConfig`

Standardmäßig ist Argumentation deaktiviert, um Geschwindigkeit und Kosten bei einfachen Abfragen zu optimieren. Wenn Sie über diese einfachen Aufgaben hinausgehen möchten, können Sie Argumentation aktivieren. Nova 2 bietet eine flexible Steuerung der Argumentationstiefe und bietet drei Aufwandsebenen:

Geringer Aufwand () `maxReasoningEffort: "low"`

AM BESTEN GEEIGNET FÜR: AUFGABEN MIT ZUSÄTZLICHER KOMPLEXITÄT, DIE STRUKTURIERTES DENKEN ERFORDERN. Sie können dies beispielsweise für Codeüberprüfungen und Verbesserungsvorschläge verwenden, bei denen das Modell die vorhandene Codequalität sorgfältig berücksichtigen muss, für Analyseaufgaben, die eine sorgfältige Berücksichtigung mehrerer Faktoren erfordern, oder für Problemlösungsszenarien, die von einem methodischen Ansatz profitieren. Ein geringer Aufwand ist ideal für komplexe Aufgaben, bei denen grundlegende Überlegungen die Genauigkeit verbessern, ohne dass eine gründliche Planung in mehreren Schritten erforderlich ist.

Mittlerer Aufwand () `maxReasoningEffort: "medium"`

AM BESTEN GEEIGNET FÜR: MEHRSTUFIGE AUFGABEN UND CODIERUNGSWORKFLOWS. Sie können dies beispielsweise für die Softwareentwicklung und das Debugging verwenden, bei denen das Modell die bestehende Codestruktur verstehen muss, bevor Änderungen implementiert werden, für die Codegenerierung, die die Koordination mehrerer Dateien oder Komponenten erfordert, für mehrstufige Berechnungen mit gegenseitigen Abhängigkeiten oder für die Planung von Aufgaben mit mehreren Einschränkungen. Ein mittlerer Aufwand ist optimal für agentische Workflows, die mehrere Tools koordinieren und erfordern, dass das Modell den Kontext mehrerer sequentieller Operationen beibehält.

Hoher Aufwand () `maxReasoningEffort: "high"`

AM BESTEN GEEIGNET FÜR: LOGISCHES DENKEN UND FORTGESCHRITTENE PROBLEMLÖSUNG. Sie können dies beispielsweise für fortgeschrittene mathematische Probleme und Beweise verwenden, die eine strenge step-by-step Überprüfung erfordern, für

wissenschaftliche Analysen und Forschungsaufgaben, die gründliche Untersuchungen erfordern, für ein komplexes Systemdesign mit architektonischen Überlegungen über mehrere Dimensionen oder für kritische Entscheidungsszenarien mit erheblichen Auswirkungen. Ein hoher Aufwand sorgt für maximale Genauigkeit bei Aufgaben, die eine ausgeklügelte Argumentation, eine sorgfältige Bewertung von Alternativen und eine gründliche Validierung der Schlussfolgerungen erfordern.

Die folgenden Beispiele zeigen die unterschiedlichen Ebenen des Argumentationsaufwands:

Low effort

```
import boto3

bedrock = boto3.client('bedrock-runtime', region_name='us-east-1')

response = bedrock.converse(
    modelId='us.amazon.nova-2-lite-v1:0',
    system=[{"text": "You are a highly capable personal assistant"}],
    messages=[{
        "role": "user",
        "content": [{"text": "Provide a meal plan for a gluten free family of 4."}]
    }],
    inferenceConfig={
        "temperature": 0.7,
        "topP": 0.9,
        "maxTokens": 10000
    },
    additionalModelRequestFields={
        "reasoningConfig": {
            "type": "enabled",
            "maxReasoningEffort": "low"
        }
    }
)
```

Parameter für das Denken:

Im Folgenden sind Argumentationsparameter aufgeführt

- type: enabled oder disabled (Standard:disabled)

- `maxReasoningEffort`: `lowmedium`, oder `high`. Dies ist erforderlich, wenn Reasoning aktiviert ist.

Note

Temperatur, TopP und TopK können nicht zusammen mit `maxReasoningEffort` der Einstellung auf verwendet werden. `high` Dies wird zu einem Fehler führen.

Die Antwort enthält Argumentationsinhalte:

```
{
  "output": {
    "message": {
      "role": "assistant",
      "content": [
        {
          "reasoningContent": {
            "reasoningText": {
              "text": "[REDACTED]"
            }
          }
        },
        {
          "text": "Based on the premises, we can conclude..."
        }
      ]
    }
  },
  "stopReason": "end_turn"
}
```

Note

Bei Amazon Nova 2 werden Argumentationsinhalte als `[REDACTED]` angezeigt. Für Argumentations-Tokens fallen weiterhin Gebühren an, da sie zu einer verbesserten Ausgabequalität beitragen. Wir nehmen dieses Feld jetzt in die Antwortstruktur auf, um die Möglichkeit zu wahren, in future Argumentationsinhalte offenzulegen. Wir arbeiten aktiv

mit unseren Kunden zusammen, um herauszufinden, wie der Argumentationsprozess des Modells am besten dargestellt werden kann.

Verwenden der Invoke-API

Die Invoke-API bietet direkten Zugriff auf Amazon Nova-Modelle mit mehr Möglichkeiten, das Anfrage- und Antwortformat zu steuern. Im Gegensatz zur Converse-API, die modellspezifische Details abstrahiert, ermöglicht Ihnen die Invoke-API, direkt mit den systemeigenen Anfrage- und Antwortstrukturen des Modells zu arbeiten.

Note

Die Invoke-API unterstützt dieselben Funktionen wie die Converse-API, mit Ausnahme der Dokumenteingabemodalität, die für die Converse-API spezifisch ist.

Struktur der Anfrage

Für eine Invoke-API-Anfrage sind die Modell-ID und ein JSON-Anforderungstext erforderlich:

```
import boto3
import json

bedrock = boto3.client('bedrock-runtime', region_name='us-east-1')

request_body = {
    'messages': [
        {
            'role': 'user',
            'content': [{'text': 'What is machine learning?'}]
        }
    ],
    'inferenceConfig': {
        'maxTokens': 512,
        'temperature': 0.7
    }
}

response = bedrock.invoke_model(
```

```
modelId='us.amazon.nova-2-lite-v1:0',
body=json.dumps(request_body)
)

response_body = json.loads(response['body'].read())
content_list = response_body["output"]["message"]["content"]
# Extract the first text block
text_block = next((item for item in content_list if "text" in item), None)
if text_block is not None:
    print(text_block["text"])
```

Anforderungsparameter

Die Invoke-API unterstützt die folgenden Schlüsselparameter:

- **messages:** Reihe von Konversationsnachrichten mit Rolle und Inhalt
- **system:** Optionale Systemaufforderung für Kontext und Anweisungen
- **inferenceConfig:** Parameter, die die Modellausgabe steuern (Temperature, MaxTokens, ToPP, TopK, StopSequences, ReasoningConfig)
- **toolConfig:** Werkzeugspezifikationen und Werkzeugauswahl für den Funktionsaufruf

Streaming-Antworten

Durch Streaming können Sie Modellantworten inkrementell empfangen, während sie generiert werden, was eine interaktivere Benutzererfahrung bietet. Sowohl die Converse API als auch die Invoke API unterstützen Streaming.

Streamen mit ConverseStream

Verwenden Sie ConverseStream diese Option, um Antworten als Stream von Ereignissen zu erhalten:

```
import boto3

bedrock = boto3.client('bedrock-runtime', region_name='us-east-1')

response = bedrock.converse_stream(
    modelId='us.amazon.nova-2-lite-v1:0',
    messages=[
```

```

        {
            'role': 'user',
            'content': [{'text': 'Write a short story about AI.'}]
        }
    ]
)

for event in response['stream']:
    if 'contentBlockDelta' in event:
        delta = event['contentBlockDelta']['delta']
        if 'text' in delta:
            print(delta['text'], end='', flush=True)

```

Streamen mit InvokeModelWithResponseStream

InvokeModelWithResponseStream Für das Streaming mit der Invoke-API verwenden:

```

import boto3
import json

bedrock = boto3.client('bedrock-runtime', region_name='us-east-1')

request_body = {
    'messages': [
        {
            'role': 'user',
            'content': [{'text': 'Explain quantum computing.'}]
        }
    ]
}

response = bedrock.invoke_model_with_response_stream(
    modelId='us.amazon.nova-2-lite-v1:0',
    body=json.dumps(request_body)
)

for event in response['body']:
    chunk = json.loads(event['chunk']['bytes'])
    if 'contentBlockDelta' in chunk:
        delta = chunk['contentBlockDelta']['delta']
        if 'text' in delta:
            print(delta['text'], end='', flush=True)

```

Ereignistypen streamen

Streaming-Antworten umfassen verschiedene Ereignistypen:

- `messageStart`: Zeigt den Beginn einer Nachricht an
- `contentBlockStart`: Zeigt den Beginn eines Inhaltsblocks an
- `contentBlockDelta`: Enthält inkrementellen Text oder Daten
- `contentBlockStop`: Zeigt das Ende eines Inhaltsblocks an
- `messageStop`: Zeigt das Ende der Nachricht mit dem Grund für den Stopp an
- `metadata`: Enthält Nutzungsinformationen (Token-Anzahl)

Verwenden von Amazon Nova-Einbettungen

Amazon Nova Multimodal Embeddings ist ein multimodales Einbettungsmodell für agentische RAG- und semantische Suchanwendungen. Es unterstützt Text, Dokumente, Bilder, Video und Audio über ein einziges Modell und ermöglicht so einen modalübergreifenden Abruf. Nova Multimodal Embeddings ordnet jeden dieser Inhaltstypen einem einheitlichen semantischen Raum zu, sodass Sie unimodale, modalübergreifende und multimodale Vektoroperationen durchführen können.

Wenn ein Inhalt durch Nova-Einbettungen geführt wird, wandelt das Modell diesen Inhalt in ein universelles numerisches Format um, das als Vektor bezeichnet wird. Ein Vektor ist ein Satz numerischer Werte, der für verschiedene Suchfunktionen verwendet werden kann. Ähnlichem Inhalt wird ein näherer Vektor zugewiesen als weniger ähnlichen Inhalten.

Anwendungen:

- **Semantischer Inhaltsabruf und Empfehlung**: Generieren Sie Einbettungen für Ihre Inhalte und verwenden Sie sie dann, um ähnliche Artikel zu finden oder personalisierte Empfehlungen abzugeben.
- **Multimodale Suche**: Kombinieren Sie Einbettungen aus verschiedenen Inhaltstypen, um modalübergreifende Suchfunktionen zu ermöglichen.
- **RAG**: Generieren Sie Einbettungen aus multimodalen Inhalten wie Dokumenten mit verschachtelten Texten und Bildern, um Ihren Abruf-Workflow für GenAI-Anwendungen zu optimieren.

Schlüssel-Features

Diese Hauptmerkmale zeichnen Nova Embeddings aus:

- Support für Text, Bild, Dokumentbild, Video und Audio in einem einheitlichen semantischen Raum. Die maximale Kontextlänge beträgt 8.000 Token oder 30 Sekunden Video und 30 Sekunden Audio.
- Synchron und asynchron APIs: Die API unterstützt sowohl die synchrone als auch die asynchrone Verwendung.
- Segmentierung großer Dateien: Die asynchrone API erleichtert die Arbeit mit großen Eingaben, indem sie eine API-basierte Segmentierung für lange Texte, Videos und Audiodateien bereitstellt, die durch benutzerdefinierte Parameter gesteuert wird. Das Modell generiert für jedes Segment eine einzige Einbettung.
- Video mit Audio: Video und Audio gleichzeitig verarbeiten. Geben Sie an, ob Sie eine einzelne Einbettung, die beide Modalitäten repräsentiert, oder zwei separate Einbettungen wünschen.
- Zweck der Einbettung: Optimieren Sie Ihre Einbettungen je nach der beabsichtigten Downstream-Anwendung (, Klassifizierung, Clustering). retrieval/RAG/Search
- Größen: Vier Größen zur Abwägung zwischen Einbettungsgenauigkeit und Vektorspeicherkosten: 3 072, 1 024, 384, 256.
- Eingabemethoden: Übergeben Sie den einzubettenden Inhalt, indem Sie eine S3-URI oder eine Inline-Version als Base64-Kodierung angeben.

Einbettungen werden generiert

Gehen Sie wie folgt vor, um Einbettungen zu generieren.

Synchrone Einbettung von Text:

```
import boto3
import json

# Create the Bedrock Runtime client.
bedrock_runtime = boto3.client(
    service_name='bedrock-runtime',
    region_name='us-east-1',
)

# Define the request body.
```

```

request_body = {
    'taskType': 'SINGLE_EMBEDDING',
    'singleEmbeddingParams': {
        'embeddingPurpose': 'GENERIC_INDEX',
        'embeddingDimension': 3072,
        'text': {'truncationMode': 'END', 'value': 'Hello, World!'},
    },
}

try:
    # Invoke the Nova Embeddings model.
    response = bedrock_runtime.invoke_model(
        body=json.dumps(request_body, indent=2),
        modelId='amazon.nova-2-multimodal-embeddings-v1:0',
        accept='application/json',
        contentType='application/json',
    )

except Exception as e:
    # Add your own exception handling here.
    print(e)

# Print the request ID.
print('Request ID:', response.get('ResponseMetadata').get('RequestId'))

# Print the response body.
response_body = json.loads(response.get('body').read())
print(json.dumps(response_body, indent=2))

```

versuche:

```

response = bedrock_runtime.invoke_model(
#####body=json.dumps(request_body, indent=2),
#####modelId='amazon.nova-2-multimodal-embeddings-v1:0',
#####accept='application/json',
#####contentType='application/json',
####)
except Exception as e:
####print(e)

print('Request ID:', response.get('ResponseMetadata').get('RequestId'))
response_body = json.loads(response.get('body').read())
print(json.dumps(response_body, indent=2))

```

Asynchrone Einbettung für Video:

```
import boto3

bedrock_runtime = boto3.client(
    #####service_name='bedrock-runtime',
    #####region_name='us-east-1',
)

model_input = {
    #####'taskType': 'SEGMENTED_EMBEDDING',
    #####'segmentedEmbeddingParams': {
    #####    #####'embeddingPurpose': 'GENERIC_INDEX',
    #####    #####'embeddingDimension': 3072,
    #####    #####'video': {
    #####        #####'format': 'mp4',
    #####        #####'embeddingMode': 'AUDIO_VIDEO_COMBINED',
    #####        #####'source': {
    #####            #####'s3Location': {'uri': 's3://my-bucket/path/to/video.mp4'}
    #####            #####},
    #####        #####'segmentationConfig': {
    #####            #####'durationSeconds': 15### Segment into 15 second chunks
    #####            #####},
    #####        #####},
    #####    },
    #####},
}
```

versuche:

```
response = bedrock_runtime.start_async_invoke(
    #####modelId='amazon.nova-2-multimodal-embeddings-v1:0',
    #####modelInput=model_input,
    #####outputDataConfig={
    #####    #####'s3OutputDataConfig': {
    #####        #####'s3Uri': 's3://my-bucket'
    #####        #####}
    #####    },
    #####)
except Exception as e:
    #####print(e)

print('Request ID:', response.get('ResponseMetadata').get('RequestId'))
print('Invocation ARN:', response.get('invocationArn'))
```

Batch-Inferenz

Mit Batch-Inferenz können Sie mehrere Anfragen einreichen und Einbettungen asynchron generieren. Batch-Inferenz hilft Ihnen, viele Anfragen effizient zu verarbeiten, indem sie eine einzige Anfrage senden und Antworten in einem Amazon S3 S3-Bucket generieren.

- Nachdem Sie Modelleingaben in von Ihnen erstellten Dateien definiert haben, laden Sie die Dateien in einen S3-Bucket hoch.
- Anschließend übermitteln Sie eine Batch-Inferenzanforderung und geben den S3-Bucket an.
- Nachdem der Auftrag abgeschlossen ist, können Sie die Ausgabedateien von S3 abrufen.
- Sie können Batch-Inferenz verwenden, um die Leistung der Modellinferenz bei großen Datensätzen zu verbessern.

Formatieren Sie Ihre Batch-Inferenzdaten und laden Sie sie hoch

Sie müssen Ihre Batch-Inferenzdaten zu einem S3-Speicherort hinzufügen, den Sie auswählen oder angeben, wenn Sie einen Auftrag zum Aufruf eines Modells übermitteln. Der S3-Standort muss die folgenden Elemente enthalten:

Mindestens eine JSONL-Datei, die die Modelleingaben definiert. Eine JSONL-Datei enthält Zeilen mit JSON-Objekten. Ihre JSONL-Datei muss die Erweiterung .jsonl sowie folgendes Format aufweisen:

```
{
  "recordId": "record001",
  "modelInput": {
    "taskType": "SINGLE_EMBEDDING",
    "singleEmbeddingParams": {
      "embeddingPurpose": "GENERIC_INDEX",
      "embeddingDimension": 3072,
      "text": {
        "source": {
          "s3Location": {
            "uri": "s3://batch-inference-input-bucket/text_001.txt",
            "bucketOwner": "111122223333"
          }
        },
        "truncationMode": "END"
      }
    }
  }
}
```



```
}
```

Unterstützte Eingabedateitypen

- Bildformate: PNG, JPEG, WEBP, GIF
- Audioformate: WAV MP3, OGG
- Videoformate: MOV MP4, MKV, WEBM, FLV, MPEG, MPG, WMV, 3GP

On-Demand-Inferenz

On-Demand-Inferenz bietet serverlosen Zugriff auf Amazon Nova-Modelle, ohne dass bereitgestellte Kapazität erforderlich ist. Dieser Modus wird automatisch skaliert, um Ihre Arbeitslast und die Gebühren je nach Nutzung zu bewältigen.

Vorteile

On-Demand-Inferenz bietet mehrere Vorteile:

- Keine Kapazitätsplanung: Automatische Skalierung, um der Nachfrage gerecht zu werden
- Bezahlung pro Nutzung: Wird nur für verarbeitete Tokens berechnet
- Sofortige Verfügbarkeit: Keine Bereitstellungs- oder Aufwärmzeit erforderlich
- Kostengünstig: Ideal für variable oder unvorhersehbare Workloads

Verwendung von On-Demand-Inferenz

On-Demand-Inferenz ist der Standardmodus für Amazon Nova-Modelle. Geben Sie bei API-Aufrufen einfach die Modell-ID an:

```
import boto3

bedrock = boto3.client('bedrock-runtime', region_name='us-east-1')

response = bedrock.converse(
    modelId='us.amazon.nova-2-lite-v1:0',
    messages=[
        {
            'role': 'user',
            'content': [{'text': 'Hello, Nova!'}]
```

```
    }  
  ]  
)  
  
# Print the response text  
content_list = response["output"]["message"]["content"]  
text = next((item["text"] for item in content_list if "text" in item), None)  
if text is not None:  
    print(text)
```

Preisgestaltung

On-Demand-Inferenzen werden auf der Grundlage der Anzahl der verarbeiteten Eingabe- und Ausgabetokens in Rechnung gestellt. Aktuelle Preisinformationen finden Sie unter [Amazon Bedrock — Preise](#).

Kontingente und -Einschränkungen

On-Demand-Inferenz hat Standardkontingente, die je nach Modell und Region variieren. Verwenden Sie die [Service Quota-Konsole, um Kontingenterhöhungen](#) anzufordern.

Nutzung der Funktionen von Amazon Nova 2

Dieses Handbuch enthält aufgabenorientierte Rezepte und praktische Beispiele, mit denen Sie die Funktionen von Nova schnell und effektiv in Ihre Anwendungen integrieren können. Es richtet sich an Entwickler und Ingenieure, die:

- Integrieren Sie Nova-Modelle über API in ihre Anwendungen
- Verstehen Sie die Anforderungen und Optimierungsstrategien für die Vorverarbeitung
- Implementieren Sie multimodale Workflows zum Verständnis

Jeder Abschnitt bietet:

- Wichtige technische Informationen zu unterstützten Formaten, Größenbeschränkungen und Token-Schätzungen
- Codebeispiele, die zeigen, wie die API sowohl mit direktem Upload als auch mit Amazon S3 verwendet wird
- Anwendungsfälle, die praktische Anwendungen zeigen
- Einschränkungen, die Sie beim Entwerfen Ihrer Anwendung berücksichtigen sollten

Voraussetzungen

Stellen Sie vor Beginn sicher, dass Sie über Folgendes verfügen:

- Und AWS-Konto mit Zugriff auf Amazon Bedrock
- Entsprechende IAM-Berechtigungen zum Aufrufen von Bedrock-Modellen
- AWS SDK installiert (Boto3 für Python-Beispiele)
- Grundkenntnisse in AWS Diensten wie Amazon S3 (für die Handhabung großer Dateien)

Fähigkeiten zum Argumentieren

Amazon Nova 2 Lite unterstützt erweitertes Denken, das standardmäßig deaktiviert ist. Wenn diese Option aktiviert ist, generiert das Modell interne Argumentationstoken, die die Antwortqualität verbessern. In Amazon Nova 2 Lite wird der Inhalt der Argumentation in der Ausgabe geschwärzt und so angezeigt[REDACTED], als ob Ihnen diese Token immer noch in Rechnung gestellt werden.

Das Feld „Begründung“ ist in der Antwortstruktur enthalten, um die Möglichkeit zu wahren, diesen Inhalt in future Versionen zu veröffentlichen. Weitere Informationen zu erweitertem Denken finden Sie unter [the section called “Erweitertes Denken”](#) und [the section called “Code-Bibliothek”](#)

Multimodales Verständnis

Amazon Nova 2 Lite kann mehrere Eingabemodalitäten verstehen. Dieses Modell ist mit Bildverarbeitungsfunktionen ausgestattet, die es ermöglichen, Bilder, Dokumente, Videos und Sprache zu verstehen und zu analysieren, um anhand der bereitgestellten Inhalte Fragen abzuleiten und zu beantworten.

In diesem Abschnitt werden Richtlinien für die Arbeit mit Bildern, Dokumenten und Videos in Amazon Nova beschrieben, einschließlich der angewandten Vorverarbeitungsstrategien, Codebeispiele und relevanter Einschränkungen, die es zu berücksichtigen gilt.

Unterstützter Inhaltstyp nach Modalität

In den folgenden Informationen werden die von den einzelnen Mediendateitypen unterstützten Dateiformate und die akzeptierte Eingabemethode detailliert beschrieben.

Typ der Mediendatei	Unterstützte Dateiformate	Eingabemethode	Größenbeschränkungen	Anzahl der Objekte
Image	PNG, JPEG, GIF, WebP	Daten in die Anfrage einbetten	25 MB	5
	Hinweis: Wenn Sie eine animierte GIF- oder WebP-Datei verwenden, wird nur der erste Frame verwendet.	Wenn Sie die Converse-API verwenden, kodieren Sie Daten als Byte. Wenn Sie die Invoke-API verwenden, kodieren Sie Daten als Base64-Zeichenfolge.		
		Amazon-S3-URI	Insgesamt 2 GB	1000

Typ der Mediendatei	Unterstützte Dateiformate	Eingabemethode	Größenbeschränkungen	Anzahl der Objekte
Video	MP4, MOV, MKV, WebM, FLV, MPEG, MPG, WMV, 3GP	Daten in die Anfrage einbetten	25 MB	1
		Wenn Sie die Converse-API verwenden, kodieren Sie Daten als Byte. Wenn Sie die Invoke-API verwenden, kodieren Sie Daten als Base64-Zeichenfolge.		
		Amazon-S3-URI	1 GB	1

Themen

- [Bildverständnis](#)
- [Video-Verständnis](#)
- [Verstehen von Dokumenten](#)

Bildverständnis

Bildverständnis bezieht sich auf die Fähigkeit von Amazon Nova, ein Bild zu verarbeiten und eine Vielzahl von Computer-Vision-Aufgaben auszuführen, wie z. B.:

- Durchführung der Objekterkennung
- Beantwortung von Fragen zu Bildern mithilfe von Visual Question Answering (VQA)
- Bilder klassifizieren und zusammenfassen
- Eine Bounding-Box-Erkennung wird durchgeführt
- Optische Zeichenerkennung (OCR)
- Zählung von Objekten

Bilder können als Eingabeaufforderung eingebunden werden, die als Byte-Arrays oder über eine S3-URI an die API übergeben wird.

Wichtige technische Informationen

Im Folgenden finden Sie wichtige technische Informationen, die Sie beachten sollten, wenn Sie mit dieser Funktion arbeiten.

Bildgröße und Neuskalierung

Amazon Nova skaliert Bilder automatisch neu, um Qualität und Leistung zu optimieren:

- Ermittelt das Seitenverhältnis, das am nächsten kommt (z. B. 1:1, 1:2, 2:3 usw.)
- Skaliert neu, sodass eine Seite ≥ 896 px oder der kürzeren Seite des Originalbilds entspricht — je nachdem, welche Seite größer ist
- Behält das Seitenverhältnis bei
- Unterstützt eine Auflösung von bis zu 8.000×8.000 px

Koordinaten des Bounding-Boxes:

- Nützlich für Aufgaben wie das Identifizieren von Elementen in Screenshots oder das Grundieren von Bildern
- Koordinaten können bei der Nachbearbeitung neu skaliert werden, sodass sie den Originalabmessungen des Bildes entsprechen
- Gibt Begrenzungsrahmen auf einer Skala von $[0, 1000]$ zurück.

Image-token Schätzung

Amazon Nova konvertiert jedes Bild zur Verarbeitung in Token. Die Anzahl der verarbeiteten Token hängt zwar von der Bildauflösung und dem Seitenverhältnis ab, die Nutzung wird jedoch pauschal mit 230 Token pro Bild abgerechnet. Beachten Sie, dass die `inputTokens` Anzahl, die vom API-Aufruf zurückgegeben wird, diese 230 Token widerspiegelt.

Beispiele zum Verständnis von Bildern

Ein Beispiel dafür, wie Sie Bilddaten direkt in die Anfrage einbetten können, finden Sie im Beispiel [Multimodale Eingabe mit eingebettetem Asset — Converse API \(non-streaming\)](#) in der [Code-Bibliothek](#)

Verwenden Sie Amazon S3, um große Bilddateien oder mehrere Bilddateien hochzuladen, bei denen die Gesamtnutzlast mehr als 25 MB beträgt. Ein vollständiges Beispiel für die Verwendung von

Amazon S3 S3-URI-Referenzen für die Bildeingabe finden Sie im Beispiel Multimodale Eingabe mit S3-URI — Converse API (non-streaming) in der. [Code-Bibliothek](#)

Note

Wenn Sie S3 verwenden, stellen Sie sicher, dass der Amazon Bedrock-Service berechtigt ist, auf den Bucket und das Objekt zuzugreifen.

Die wichtigsten Einschränkungen

In der folgenden Liste werden die aktuellen Einschränkungen von Modellen zum Verständnis von Bildern beschrieben:

- **Verständnis mehrsprachiger Bilder:** Die Modelle verstehen mehrsprachige Bilder und Videoframes nur begrenzt und können bei einfachen Aufgaben Probleme haben oder halluzinieren.
- **Identifizierung von Personen:** Amazon Nova 2-Modelle unterstützen nicht die Möglichkeit, Personen in Bildern, Dokumenten oder Videos zu identifizieren oder zu benennen.
- **Räumliches Denken:** Die Modelle von Amazon Nova 2 verfügen nur über begrenzte Fähigkeiten zum räumlichen Denken. Sie haben möglicherweise Probleme mit Aufgaben, die eine genaue Lokalisierungs- oder Layoutanalyse erfordern.
- **Kleiner Text in Bildern und Videos:** Wenn der Text im Bild oder Video zu klein ist, sollten Sie erwägen, die relative Größe des Textes im Bild zu erhöhen, indem Sie den entsprechenden Abschnitt beschneiden und dabei den erforderlichen Kontext beibehalten.

Video-Verständnis

Videoverständnis bezieht sich auf die Fähigkeit von Amazon Nova, Videoeingänge zu verarbeiten und eine Reihe von Videoverständnisaufgaben auszuführen, wie z. B.:

- Analyse von Schlüsselbildern und Zusammenfassung von Videoinhalten
- Beantwortung von Fragen zu Videosegmenten (Beantwortung von Videofragen oder Video-QA)
- Objekte über Frames hinweg erkennen und verfolgen
- Identifizieren von Aktionen, Szenen und Ereignissen
- Durchführung einer zeitlichen Segmentierung zur Lokalisierung bestimmter Momente
- Generierung beschreibender Bildunterschriften oder Zusammenfassungen von Videosequenzen

Wichtige technische Informationen

Im Folgenden finden Sie wichtige technische Informationen, die Sie beachten sollten, wenn Sie mit dieser Funktion arbeiten.

Informationen zur Videogröße

Die Videoverstehensfunktionen von Amazon Nova unterstützen das Multi-Seitenverhältnis. Alle Videos werden verzerrt (nach oben oder unten, basierend auf dem ursprünglichen Seitenverhältnis) auf 672 × 672 Quadratabmessungen skaliert, bevor sie in das Modell eingegeben werden.

Das Modell verwendet eine dynamische Sampling-Strategie, die auf der Videolänge basiert. Für Videos mit einer Länge von 16 Minuten oder weniger tastet Amazon Nova 2 Lite 1 Bild pro Sekunde (FPS) ab. Bei Videos, die länger als 16 Minuten sind, verringert sich die Abtastrate, um einen gleichbleibenden Wert von 960 Bildern aufrechtzuerhalten, wobei die Frame-Abtastrate entsprechend variiert. Dieser Ansatz wurde entwickelt, um kürzere Videos im Vergleich zu längeren Videoinhalten genauer auf Szenenebene zu verstehen.

Wir empfehlen, die Videolänge bei niedriger Bewegung unter 1 Stunde und bei viel Bewegung unter 16 Minuten zu halten.

Bei der Analyse einer 4k-Version eines Videos und einer Full-HD-Version sollte kein Unterschied bestehen. Da die Abtastrate 1 FPS beträgt, sollte ein Video mit 60 Bildern pro Sekunde genauso gut funktionieren wie ein Video mit 30 Bildern pro Sekunde. Die Verwendung einer höheren Auflösung und einer höheren Bildrate als erforderlich ist nicht vorteilhaft, da die Videogröße auf 1 GB begrenzt ist. Dadurch wird die Videolänge begrenzt, die in diese Größenbeschränkung passt. Sie sollten also Videos mit einer Länge von mehr als 1 GB vorverarbeiten.

Video-Token

Die Länge des Videos ist der Hauptfaktor, der sich auf die Anzahl der generierten Token auswirkt. Um die ungefähren Kosten zu berechnen, multiplizieren Sie die geschätzte Anzahl der Video-Token mit dem Preis pro Token für das jeweils verwendete Modell.

Die folgende Tabelle enthält einige ungefähre Angaben zur Frame-Sampling und Token-Nutzung pro Videolänge für Amazon Nova 2 Lite:

Länge des Videos	Bilder zum Ausprobieren	Abtaste rate pro Sekunde	Ungefähre Tokens
10 Sekunden	10	1	2.880
30 Sekunden	30	1	8.640
16 Minuten	960	1	276.480
20 Minuten	1200	1	345.600
30 Minuten	1800	1	518.400
45 Minuten	2700	1	777.600

Beispiele zum Videoverständnis

Ein Beispiel dafür, wie Sie Videodaten direkt in die Anfrage einbetten können, finden Sie im Beispiel [Multimodale Eingabe mit eingebettetem Asset — Converse API \(kein Streaming\)](#) in der [Code-Bibliothek](#)

Ein Beispiel für die Verwendung von S3-URI-Referenzen bei der Videoeingabe finden Sie im Beispiel [Multimodale Eingabe mithilfe von S3-URI — Converse API \(kein Streaming\)](#) in der [Code-Bibliothek](#)

Wichtigste Einschränkungen

Im Folgenden sind die wichtigsten Einschränkungen des Modells aufgeführt, bei denen die Genauigkeit und Leistung des Modells möglicherweise nicht garantiert werden kann:

- **Keine Audiounterstützung:** Die Amazon Nova-Modelle sind derzeit darauf trainiert, Videoinhalte ausschließlich auf der Grundlage der visuellen Frames zu verarbeiten und zu verstehen. Audiospuren in Videos werden nicht verarbeitet oder analysiert.
- **Verständnis mehrsprachiger Bilder:** Die Amazon Nova-Modelle verstehen mehrsprachige Bilder und Videoframes nur begrenzt. Sie könnten bei einfachen Aufgaben Probleme haben oder halluzinieren.
- **Identifizierung von Personen:** Die Amazon-Nova-Modelle unterstützen nicht die Möglichkeit, Personen in Bildern, Dokumenten oder Videos zu identifizieren oder zu benennen. Die Modelle enthalten keine Namen oder Identitäten von Personen in visuellen Inhalten.

- **Kleiner Text in Videos:** Wenn der Text im Bild oder Video zu klein ist, erwägen Sie, den Text im Video relativ zu vergrößern.
- **Räumliches Denken:** Die Modelle von Amazon Nova 2 verfügen nur über begrenzte Fähigkeiten zum räumlichen Denken. Sie haben möglicherweise Probleme mit Aufgaben, die ein genaues Verständnis von Objektpositionen, Entfernungen oder räumlichen Beziehungen in Videos erfordern.
- **Unangemessene Inhalte:** Die Amazon-Nova-Modelle verarbeiten keine unangemessenen oder expliziten Bilder, die gegen die Richtlinie zur zulässigen Nutzung verstoßen.
- **Anwendungen im Gesundheitswesen:** Aufgrund der Sensibilität dieser Artefakte empfehlen wir nicht, sie zur Interpretation sensibler medizinischer Bilder oder Videos wie komplexe diagnostische Scans zu verwenden, obwohl Amazon Nova-Modelle allgemeine Analysen für einige Bilder oder Videos aus dem Gesundheitswesen ermöglichen könnten. Die Reaktion der Amazon Nova-Modelle sollte niemals als Ersatz für professionellen medizinischen Rat angesehen werden.

Verstehen von Dokumenten

Mit der Funktion zum Verstehen von Dokumenten von Amazon Nova können Sie ganze Dokumente (PDFs, Word-Dateien, Tabellen usw.) in Ihre Aufforderung einbeziehen. Auf diese Weise kann das Modell den Inhalt von Dokumenten analysieren, zusammenfassen, Informationen daraus extrahieren oder Fragen dazu beantworten.

Amazon Nova 2 Lite kann sowohl den Text als auch die visuellen Elemente (wie Diagramme oder Tabellen) in diesen Dokumenten interpretieren. Dies ermöglicht Anwendungsfälle wie die Beantwortung von Fragen, die Zusammenfassung und Analyse umfangreicher Berichte oder gescannter Dokumente.

Zu den wichtigsten Funktionen für das Verständnis von Dokumenten gehören ein sehr großes Kontextfenster (1 Million Token) für umfangreiche Dokumente und die Möglichkeit, mehrere Dokumente in einer Abfrage zu verarbeiten.

Unterstützte Modalitäten und Formate für Dokumente

Amazon Nova unterscheidet zwischen zwei Arten von Dokumenteneingaben:

- **Text-basierte Dokumente** wie TXT-, CSV-, HTML-, Markdown- oder DOC-Dateien werden hauptsächlich aufgrund ihres Textinhalts verarbeitet. Amazon Nova versteht und extrahiert Informationen aus dem Text in diesen Dokumenten.
- **Media-basierte Dokumente**, wie PDF- oder DOCX-Dateien, können komplexe Layouts, Bilder, Diagramme oder eingebettete Grafiken enthalten. Bei medienbasierten Dokumenten verwendet

Amazon Nova visuelles Verständnis, um visuelle Inhalte — wie Diagramme, Tabellen, Diagramme oder Screenshots — zusammen mit dem Text des Dokuments zu interpretieren.

Zu den unterstützten Dateiformaten gehören gängige Dokumenttypen wie:

- Klartext- und strukturierte Textdateien: CSV, TXT
- Tabellenkalkulationen: XLS, XLSX, HTML, Markdown
- Standard-Bildformate (für Bilder in Dokumenten): PNG, JPG, GIF, WebP
- Dokumentenformate: DOC, DOCX, PDF
- PDFs, die Bildkodierungen wie CMYK oder SVG enthalten, werden nicht unterstützt.

Größenbeschränkungen und Nutzungsrichtlinien für Dokumente

Einschränkung	Limit
Maximale Anzahl von Dokumenten	Bis zu 5 Dokumente pro Anfrage (gilt sowohl für den direkten Upload als auch für Amazon S3)
Text-based Größe des Dokuments	Jedes Textdokument muss 4,5 MB oder weniger groß sein
Media-based Größe des Dokuments	Für PDF- und DOCX-Dateien gibt es keine individuelle Dateigrößenbeschränkung. Beim direkten Upload muss die Gesamtgröße aller Mediendokumente höchstens 25 MB betragen. Bei Verwendung von Amazon S3 muss die Gesamtgröße aller Mediendokumente kleiner oder gleich 2 GB sein.
PDF-Inhalte werden nicht unterstützt	PDFs, die CMYK-Farbprofile oder SVG-Bilder enthalten, werden nicht unterstützt.

Preisgestaltung

Amazon Nova verwendet eine tokenbasierte Preisgestaltung: Sie zahlen für Eingabe-Token (alles, was Sie senden, einschließlich angehängter Dokumente) und Output-Token (die Antwort des Modells).

Schätzung von Tokens für PDF-Dateien: Gehen Sie bei der Planung von einer standardmäßigen 8,5 x 11 Zoll großen PDF-Seite $\approx$ 2.560 Eingabe-Tokens aus (diese Schätzung deckt sowohl Text- als auch visuelle Elemente auf einer typischen Seite ab).

Beispiele: Nutzung von Novas Document Understanding über API und S3

Ein Beispiel für die Verwendung per API finden Sie im Beispiel Multimodale Eingabe mit eingebettetem Asset — Converse API (kein Streaming) in der. [Code-Bibliothek](#)

Ein Beispiel für die Verwendung über S3 finden Sie im Beispiel Multimodale Eingabe mit S3-URI — Converse API (kein Streaming) in der. [Code-Bibliothek](#)

Speech-to-Speech (Amazon Nova 2 Sonic)

Amazon Nova 2 Sonic ermöglicht Konversations-KI in Echtzeit mit Spracheingabe und -ausgabe. Der folgende Abschnitt behandelt erweiterte Funktionen für die Erstellung interaktiver Sprachassistenten, die Automatisierung des Kundendienstes und Konversationsanwendungen.

Schlüssel-Features

Amazon Nova 2 Sonic bietet die folgenden Funktionen:

- State-of-the-art Streaming-Sprachverständnis mit bidirektionaler Streaming-API, die Multi-Turn-Konversationen in Echtzeit und mit geringer Latenz ermöglicht.
- Mehrsprachiger Support mit automatischer Spracherkennung und Sprachumschaltung. Ausdrucksstarke Stimmen, darunter sowohl männlich als auch weiblich klingende Stimmen, werden in den folgenden Sprachen angeboten:
 - Englisch (USA, Großbritannien, Indien, Australien)
 - Französisch
 - Italienisch
 - Deutsch
 - Spanisch
 - Portugiesisch
 - Hindi
- Mehrsprachige Stimmen, die jede der unterstützten Sprachen sprechen können, um ein einheitliches Benutzererlebnis zu gewährleisten, auch wenn der Benutzer innerhalb derselben Sitzung die Sprache wechselt.
- Robustheit gegenüber Hintergrundgeräuschen für reale Einsatzszenarien.
- Robustheit gegenüber unterschiedlichen Akzenten für unterstützte Sprachen.
- Natürliche, menschenähnliche KI-Konversationserlebnisse mit kontextuellem Reichtum in allen unterstützten Sprachen.
- Adaptive Sprachantwort, welche die Wiedergabe dynamisch an den Sprachstil der Eingabesprache anpasst.
- Intelligentes Abwechseln, das erkennt, wann Benutzer mit dem Sprechen fertig sind und wann der Assistent antworten sollte, wodurch ein natürlicher Dialogrhythmus entsteht.

- Reibungsloser Umgang mit Benutzerunterbrechungen, ohne den Konversationskontext zu verlieren.
- Wissensgenerierung mit Unternehmensdaten mit Retrieval Augmented Generation (RAG).
- Funktionsaufruf und Unterstützung agentenbasierter Workflows für die Erstellung komplexer KI-Anwendungen.
- Asynchrone Werkzeugverwaltung, bei der Werkzeuganrufe ausgeführt und gleichzeitig der Gesprächsfluss aufrechterhalten wird, sodass der Assistent weitersprechen kann, während die Tools im Hintergrund verarbeitet werden.
- Cross-modal Eingabeunterstützung für Audio- und Texteingaben innerhalb derselben Konversation, wodurch flexible Interaktionsmuster ermöglicht werden.
- Verbindungslimit von 8 Minuten, wobei das Muster für Verbindungserneuerung und Sitzungsfortsetzung in Codebeispielen verfügbar ist.

Erste Schritte mit Speech-to-Speech

Die folgenden Abschnitte enthalten ein Beispiel und eine schrittweise Erklärung für die Implementierung einer einfachen Audio-Streaming-Anwendung in Echtzeit mit Amazon Nova 2 Sonic. Diese vereinfachte Version demonstriert die Kernfunktionen, die für die Erstellung einer Audiokonversation mit dem Amazon Nova 2 Sonic-Modell erforderlich sind.

Sie können auf das folgende Beispiel in unserem [GitHubNova-Beispiel-Repo](#) zugreifen.

Es besteht ein Verbindungslimit von 8 Minuten. Das Muster für Verbindungserneuerung und Gesprächsfortsetzung ist verfügbar [GitHub](#).

Importe und Konfiguration angeben

In diesem Abschnitt werden die erforderlichen Bibliotheken importiert und die Audiokonfigurationsparameter festgelegt:

- `asyncio`: Für die asynchrone Programmierung
- `base64`: Zum Kodieren und Dekodieren von Audiodaten
- `pyaudio`: Für Audioaufnahme und -wiedergabe
- Amazon-Bedrock-SDK-Komponenten für Streaming
- Audiokonstanten definieren das Format der Audioaufnahme (16 kHz Samplerate, Monokanal)

```
import os
import asyncio
import base64
import json
import uuid
import pyaudio
from aws_sdk_bedrock_runtime.client import BedrockRuntimeClient,
    InvokeModelWithBidirectionalStreamOperationInput
from aws_sdk_bedrock_runtime.models import
    InvokeModelWithBidirectionalStreamInputChunk, BidirectionalInputPayloadPart
from aws_sdk_bedrock_runtime.config import Config, HTTPAuthSchemeResolver,
    SigV4AuthScheme
from smithy_aws_core.identity import EnvironmentCredentialsResolver

# Audio configuration
INPUT_SAMPLE_RATE = 16000
OUTPUT_SAMPLE_RATE = 24000
CHANNELS = 1
FORMAT = pyaudio.paInt16
CHUNK_SIZE = 1024
```

Definieren der **SimpleNovaSonic**-Klasse

Die SimpleNovaSonic-Klasse ist die Hauptklasse, welche die Interaktion mit Amazon Nova Sonic verwaltet:

- `model_id`: Die Modell-ID von Amazon Nova Sonic (`amazon.nova-2-sonic-v1:0`)
- `region`: Die AWS Region, die Standardeinstellung ist `us-east-1`
- Eindeutige IDs für Prompts und Inhaltsverfolgung
- Eine asynchrone Warteschlange für die Audiowiedergabe

```
class SimpleNovaSonic:
    def __init__(self, model_id='amazon.nova-2-sonic-v1:0', region='us-east-1'):
        self.model_id = model_id
        self.region = region
        self.client = None
        self.stream = None
        self.response = None
        self.is_active = False
        self.prompt_name = str(uuid.uuid4())
```

```
self.content_name = str(uuid.uuid4())
self.audio_content_name = str(uuid.uuid4())
self.audio_queue = asyncio.Queue()
self.display_assistant_text = False
```

Initialisieren des -Client

Diese Methode konfiguriert den Amazon-Bedrock-Client wie folgt:

- Den entsprechenden Endpunkt für die angegebene Region
- Authentifizierungsinformationen unter Verwendung von Umgebungsvariablen für AWS - Anmeldeinformationen
- Das SigV4-Authentifizierungsschema für die AWS API-Aufrufe

```
def _initialize_client(self):
    """Initialize the Bedrock client."""
    config = Config(
        endpoint_uri=f"https://bedrock-runtime.{self.region}.amazonaws.com",
        region=self.region,
        aws_credentials_identity_resolver=EnvironmentCredentialsResolver(),
        auth_scheme_resolver=HTTPAuthSchemeResolver(),
        auth_schemes={"aws.auth#sigv4": SigV4AuthScheme(service="bedrock")}
    )
    self.client = BedrockRuntimeClient(config=config)
```

Behandlung von Ereignissen

Diese Hilfsmethode sendet JSON-Ereignisse an den bidirektionalen Stream, der für die gesamte Kommunikation mit dem Amazon-Nova-Sonic-Modell verwendet wird:

```
async def send_event(self, event_json):
    """Send an event to the stream."""
    event = InvokeModelWithBidirectionalStreamInputChunk(
        value=BidirectionalInputPayloadPart(bytes_=event_json.encode('utf-8'))
    )
    await self.stream.input_stream.send(event)
```


Die Sitzung starten

Diese Methode initiiert die Sitzung und richtet die verbleibenden Ereignisse ein, um das Audio-Streaming zu starten. Das Senden dieser Ereignisse muss in der gleichen Reihenfolge erfolgen.

```
async def start_session(self):
    """Start a new session with Nova Sonic."""
    if not self.client:
        self._initialize_client()

    # Initialize the stream
    self.stream = await self.client.invoke_model_with_bidirectional_stream(
        InvokeModelWithBidirectionalStreamOperationInput(model_id=self.model_id)
    )
    self.is_active = True

    # Send session start event
    session_start = ''
    {
        "event": {
            "sessionStart": {
                "inferenceConfiguration": {
                    "maxTokens": 1024,
                    "topP": 0.9,
                    "temperature": 0.7
                },
                "turnDetectionConfiguration": {
                    "endpointingSensitivity": "HIGH"
                }
            }
        }
    }
    ...
    await self.send_event(session_start)

    # Send prompt start event
    prompt_start = f''
    {{
        "event": {{
            "promptStart": {{
                "promptName": "{self.prompt_name}",
                "textOutputConfiguration": {{
                    "mediaType": "text/plain"
```

```

        },
        "audioOutputConfiguration": {
            "mediaType": "audio/lpcm",
            "sampleRateHertz": 24000,
            "sampleSizeBits": 16,
            "channelCount": 1,
            "voiceId": "matthew",
            "encoding": "base64",
            "audioType": "SPEECH"
        }
    }
}
}
}
...
await self.send_event(prompt_start)

# Send system prompt
text_content_start = f'''
{{
    "event": {
        "contentStart": {
            "promptName": "{self.prompt_name}",
            "contentName": "{self.content_name}",
            "type": "TEXT",
            "interactive": true,
            "role": "SYSTEM",
            "textInputConfiguration": {
                "mediaType": "text/plain"
            }
        }
    }
}}
}
}
...
await self.send_event(text_content_start)

system_prompt = "You are a friendly assistant. The user and you will engage in
a spoken dialog " \
    "exchanging the transcripts of a natural real-time conversation. Keep your
responses short, " \
    "generally two or three sentences for chatty scenarios."

text_input = f'''
{{

```

```

        "event": {{
            "textInput": {{
                "promptName": "{self.prompt_name}",
                "contentName": "{self.content_name}",
                "content": "{system_prompt}"
            }}
        }}
    }}
    ...
    await self.send_event(text_input)

    text_content_end = f'''
    {{
        "event": {{
            "contentEnd": {{
                "promptName": "{self.prompt_name}",
                "contentName": "{self.content_name}"
            }}
        }}
    }}
    ...
    await self.send_event(text_content_end)

    # Start processing responses
    self.response = asyncio.create_task(self._process_responses())

```

Behandlung der Audioeingabe

Diese Methoden behandeln den Lebenszyklus der Audioeingabe:

- `start_audio_input`: Konfiguriert und startet den Audioeingangsstream
- `send_audio_chunk`: Kodiert Audioblöcke und sendet sie an das Modell
- `end_audio_input`: Schließt den Audioeingangsstream ordnungsgemäß

```

async def start_audio_input(self):
    """Start audio input stream."""
    audio_content_start = f'''
    {{
        "event": {{
            "contentStart": {{
                "promptName": "{self.prompt_name}",

```

```

        "contentName": "{self.audio_content_name}",
        "type": "AUDIO",
        "interactive": true,
        "role": "USER",
        "audioInputConfiguration": {{
            "mediaType": "audio/lpcm",
            "sampleRateHertz": 16000,
            "sampleSizeBits": 16,
            "channelCount": 1,
            "audioType": "SPEECH",
            "encoding": "base64"
        }}
    }}
}}
...
await self.send_event(audio_content_start)

async def send_audio_chunk(self, audio_bytes):
    """Send an audio chunk to the stream."""
    if not self.is_active:
        return

    blob = base64.b64encode(audio_bytes)
    audio_event = f'''
    {{
        "event": {{
            "audioInput": {{
                "promptName": "{self.prompt_name}",
                "contentName": "{self.audio_content_name}",
                "content": "{blob.decode('utf-8')}"
            }}
        }}
    }}
    ...
    await self.send_event(audio_event)

async def end_audio_input(self):
    """End audio input stream."""
    audio_content_end = f'''
    {{
        "event": {{
            "contentEnd": {{
                "promptName": "{self.prompt_name}",

```

```

        "contentName": "{self.audio_content_name}"
    }}
}}
...
await self.send_event(audio_content_end)

```

Beenden der Sitzung

Diese Methode schließt die Sitzung ordnungsgemäß durch:

- Das Senden von promptEnd-Ereignissen
- Das Senden von sessionEnd-Ereignissen
- Das Schließen des Eingabestreams

```

async def end_session(self):
    """End the session."""
    if not self.is_active:
        return

    prompt_end = f'''
    {{
        "event": {{
            "promptEnd": {{
                "promptName": "{self.prompt_name}"
            }}
        }}
    }}
    ...
    await self.send_event(prompt_end)

    session_end = '''
    {
        "event": {
            "sessionEnd": {}
        }
    }
    ...
    await self.send_event(session_end)
    # close the stream
    await self.stream.input_stream.close()

```

Umgang mit Antworten

Diese Methode verarbeitet kontinuierlich Antworten aus dem Modell und führt Folgendes aus:

- Warten auf die Ausgabe aus dem Stream.
- Analysieren der JSON-Antwort.
- Verarbeiten der Textausgabe durch Drucken auf der Konsole mit automatischer Spracherkennung und Transkription.
- Verwalten der Audioausgabe durch Dekodierung und Warteschleife für die Wiedergabe.

```
async def _process_responses(self):
    """Process responses from the stream."""
    try:
        while self.is_active:
            output = await self.stream.await_output()
            result = await output[1].receive()

            if result.value and result.value.bytes_:
                response_data = result.value.bytes_.decode('utf-8')
                json_data = json.loads(response_data)

                if 'event' in json_data:
                    # Handle content start event
                    if 'contentStart' in json_data['event']:
                        content_start = json_data['event']['contentStart']
                        # set role
                        self.role = content_start['role']
                        # Check for speculative content
                        if 'additionalModelFields' in content_start:
                            additional_fields =
                                json.loads(content_start['additionalModelFields'])
                            if additional_fields.get('generationStage') ==
                                'SPECULATIVE':
                                self.display_assistant_text = True
                            else:
                                self.display_assistant_text = False

                    # Handle text output event
                    elif 'textOutput' in json_data['event']:
                        text = json_data['event']['textOutput']['content']
```

```

        if (self.role == "ASSISTANT" and
self.display_assistant_text):
            print(f"Assistant: {text}")
        elif self.role == "USER":
            print(f"User: {text}")

        # Handle audio output
        elif 'audioOutput' in json_data['event']:
            audio_content = json_data['event']['audioOutput']
['content']

            audio_bytes = base64.b64decode(audio_content)
            await self.audio_queue.put(audio_bytes)
    except Exception as e:
        print(f"Error processing responses: {e}")

```

Audio wiedergeben

Das Verfahren führt die folgenden Aufgaben durch:

- Initialisieren eines PyAudio-Eingabestreams
- Empfängt kontinuierlich Audiodaten aus der Warteschlange
- Spielt den Ton über die Lautsprecher ab
- Bereinigt Ressourcen ordnungsgemäß nach Abschluss

```

async def play_audio(self):
    """Play audio responses."""
    p = pyaudio.PyAudio()
    stream = p.open(
        format=FORMAT,
        channels=CHANNELS,
        rate=OUTPUT_SAMPLE_RATE,
        output=True
    )

```

versuche:

```

while self.is_active:
    audio_data = await self.audio_queue.get()

```

```
        stream.write(audio_data)
    except Exception as e:
        print(f"Error playing audio: {e}")
    finally:
        stream.stop_stream()
        stream.close()
        p.terminate()
```

Audio aufnehmen

Das Verfahren führt die folgenden Aufgaben durch:

- Initialisiert einen PyAudio Ausgabestrom
- Startet die Audioeingabesitzung
- Nimmt kontinuierlich Audiodateien vom Mikrofon auf
- Sendet jeden Block an das Amazon-Nova-Sonic-Modell
- Bereinigt Ressourcen ordnungsgemäß nach Abschluss

```
async def capture_audio(self):
    """Capture audio from microphone and send to Nova Sonic."""
    p = pyaudio.PyAudio()
    stream = p.open(
        format=FORMAT,
        channels=CHANNELS,
        rate=INPUT_SAMPLE_RATE,
        input=True,
        frames_per_buffer=CHUNK_SIZE
    )

    print("Starting audio capture. Speak into your microphone...")
    print("Press Enter to stop...")

    await self.start_audio_input()
```

versuche:

```
while self.is_active:
```



```
        audio_data = stream.read(CHUNK_SIZE, exception_on_overflow=False)
        await self.send_audio_chunk(audio_data)
        await asyncio.sleep(0.01)
    except Exception as e:
        print(f"Error capturing audio: {e}")
    finally:
        stream.stop_stream()
        stream.close()
        p.terminate()
        print("Audio capture stopped.")
        await self.end_audio_input()
```

Die Hauptfunktion ausführen

Die Hauptfunktion orchestriert den gesamten Prozess, indem sie Folgendes ausführt:

- Erzeugt einen Amazon Nova 2 Sonic Client
- Sitzung starten
- Erstellt gleichzeitige Aufgaben für die Audiowiedergabe und -aufnahme
- Wartet darauf, dass der Benutzer **Enter** zum Beenden drückt
- Beendet die Sitzung ordnungsgemäß und bereinigt Aufgaben

```
async def main():
    # Create Nova Sonic client
    nova_client = SimpleNovaSonic()

    # Start session
    await nova_client.start_session()

    # Start audio playback task
    playback_task = asyncio.create_task(nova_client.play_audio())

    # Start audio capture task
    capture_task = asyncio.create_task(nova_client.capture_audio())

    # Wait for user to press Enter to stop
    await asyncio.get_event_loop().run_in_executor(None, input)

    # End session
    nova_client.is_active = False
```

```
# First cancel the tasks
tasks = []
if not playback_task.done():
    tasks.append(playback_task)
if not capture_task.done():
    tasks.append(capture_task)
for task in tasks:
    task.cancel()
if tasks:
    await asyncio.gather(*tasks, return_exceptions=True)

# cancel the response task
if nova_client.response and not nova_client.response.done():
    nova_client.response.cancel()

await nova_client.end_session()
print("Session ended")

if __name__ == "__main__":
    # Set AWS credentials if not using environment variables
    # os.environ['AWS_ACCESS_KEY_ID'] = "your-access-key"
    # os.environ['AWS_SECRET_ACCESS_KEY'] = "your-secret-key"
    # os.environ['AWS_DEFAULT_REGION'] = "us-east-1"

    asyncio.run(main())
```

Codebeispiele

Diese Codebeispiele helfen Ihnen, schnell mit Amazon Nova 2 Sonic zu beginnen. Die vollständige Liste der Beispiele finden Sie auf der [Amazon Nova GitHub Sonic-Beispielseite](#).

Erste Schritte, Beispiele

Einfache Beispiele für den Einstieg in Amazon Nova 2 Sonic finden Sie in den folgenden Implementierungen:

- [Grundlegende Amazon Nova 2 Sonic-Implementierung \(Python\)](#): Eine grundlegende Implementierung, die demonstriert, wie Ereignisse in der bidirektionalen Streaming-API strukturiert sind. Diese Version unterstützt keine Barge-In-Funktionalität (der Assistent wird unterbrochen, während er spricht) und implementiert keine echte bidirektionale Kommunikation.

- [Amazon Nova 2 Sonic-Implementierung mit vollem Funktionsumfang \(Python\)](#): Die Implementierung mit vollem Funktionsumfang mit echter bidirektionaler Kommunikation und Barge-In-Unterstützung. Dies ermöglicht natürlichere Konversationen, bei denen Benutzer den Assistenten unterbrechen können, während er spricht, ähnlich wie bei menschlichen Gesprächen.
- [Amazon Nova 2 Sonic mit Werkzeugnutzung \(Python\)](#): Eine erweiterte Implementierung, die die bidirektionalen Kommunikationsmöglichkeiten um Beispiele für die Verwendung von Tools erweitert. Diese Version zeigt, wie Amazon Nova 2 Sonic mit externen Tools und APIs interagieren kann, um erweiterte Funktionen bereitzustellen.
- [Nova Sonic mit Text und gemischter Eingabe \(Python\)](#): Beispielimplementierung zur Veranschaulichung, wie Amazon Nova 2 Sonic Text als Eingabe verwenden kann.
- [WebSocket Java-Implementierung \(Java\)](#): In diesem Beispiel wird eine bidirektionale WebSocket-based Audio-Streaming-Anwendung implementiert, die in Amazon Nova 2 Sonic integriert ist, um Speech-to-Speech-Konversationen in Echtzeit mit Java zu ermöglichen.
- [NodeJS Websocket-Implementierung \(NodeJS\)](#): In diesem Beispiel wird eine bidirektionale WebSocket-based Audio-Streaming-Anwendung implementiert, die in Amazon Nova 2 Sonic integriert ist, um Speech-to-Speech-Konversationen in Echtzeit mit NodeJS zu ermöglichen.
- [NodeJS Websocket-Implementierung \(C#\)](#): In diesem Beispiel wird eine bidirektionale WebSocket-based Audio-Streaming-Anwendung implementiert, die in Amazon Nova 2 Sonic integriert ist und Speech-to-Speech-Konversationen über .NET in Echtzeit ermöglicht.

Fortgeschrittene Anwendungsfälle

Fortgeschrittene Beispiele für komplexere Anwendungsfälle finden Sie in den folgenden Implementierungen:

- [Implementierung der Amazon Bedrock Knowledge Base \(NodeJS\)](#): Dieses Beispiel zeigt, wie Sie mithilfe von NodeJS eine intelligente Konversationsanwendung erstellen, indem Sie Amazon Nova 2 Sonic mit Amazon Bedrock Knowledge Base integrieren.
- [Verwaltung des Chat-Verlaufs \(Python\)](#): Dieses Beispiel beinhaltet ein System zur Protokollierung des Chat-Verlaufs, das alle Interaktionen zwischen dem Benutzer und Amazon Nova 2 Sonic mithilfe von Python erfasst und speichert.
- [Stornierung von Hotelreservierungen \(NodeJS\)](#): Dieses Beispiel zeigt einen praktischen Kundenservice-Anwendungsfall für Amazon Nova 2 Sonic, bei dem ein System zur Stornierung von Hotelreservierungen mithilfe von NodeJS implementiert wird.

- [LangChain Knowledge Base-Integration \(Python\)](#): Diese Implementierung zeigt, wie die Sprache-to-Speech-Funktionen von Amazon Nova 2 Sonic mit einer LangChain-powered Wissensdatenbank für verbesserte Konversationserlebnisse mit Python integriert werden können.
- [Konversationswiederaufnahme \(NodeJS\)](#): Dieses Beispiel zeigt, wie Funktionen zur Wiederaufnahme von Konversationen mit Amazon Nova 2 Sonic implementiert werden. Anhand eines Szenarios zur Stornierung von Hotelreservierungen als Kontext zeigt die Anwendung, wie der Konversationsstatus sitzungsübergreifend beibehalten werden kann, sodass Benutzer Interaktionen, die zuvor mit NodeJS unterbrochen wurden, nahtlos fortsetzen können.
- [Nova 2 Sonic Speaks First \(NodeJS\)](#): Dieses Beispiel zeigt, wie Amazon Nova 2 Sonic Konversationen proaktiv initiieren kann.
- [Sitzungsfortsetzung \(Python\)](#): Dieses Beispiel zeigt, wie Sie mit Amazon Nova 2 Sonic eine unbegrenzte Gesprächslänge aktivieren können, indem Sie nahtlose Sitzungsübergänge implementieren. Die Anwendung erstellt automatisch neue Sitzungen im Hintergrund und wechselt zu ihnen, sodass Konversationen unbegrenzt ohne Unterbrechung oder Kontextverlust fortgesetzt werden können.

Hands-on Werkstatt

Es steht ein praktischer Workshop zur Verfügung, der Sie durch die Erstellung einer Voice-Chat-Anwendung mit Amazon Nova 2 Sonic mit einer bidirektionalen Streaming-Schnittstelle führt. Sie können [auf den Workshop zugreifen](#) und die [vollständigen Codebeispiele](#) finden.

Eingabeaufforderungen für Sprachgespräche

Nova 2 führt Speech Prompts ein — eine spezielle Aufforderungsfunktion, mit der die sprachspezifische Transkriptionsformatierung für Hindi gesteuert werden kann. Sprachansagen funktionieren zusammen mit Ihrer Systemaufforderung, erfüllen jedoch einen bestimmten Zweck:

- Systemaufforderung: Steuert das Verhalten, die Persönlichkeit und den Antwortstil Ihres Assistenten
- Sprachaufforderung: Steuert die Transkriptionsformatierung für die Umschaltung zwischen Hindi-Codes (Skripte) Latin/Devanagari/mixed

Wichtige Richtlinien

Sprachansagen sind vorkonfiguriert und sollten genau wie dokumentiert verwendet werden. Sie wurden für spezielle Anforderungen an die Formatierung von Transkriptionen entwickelt und sollten nicht geändert oder angepasst werden, da Änderungen zu unerwartetem Verhalten führen können.

Wann sollten Sprachansagen verwendet werden:

- Sie müssen die Skriptausgabe für die Hindi-Code-Switching steuern () Latin/Devanagari/mixed

Wann sollten Sie Sprachansagen NICHT verwenden:

- Für allgemeine Anweisungen oder das Verhalten des Assistenten (verwenden Sie stattdessen die Systemaufforderung)
- Wenn Sie nicht mit der Transkriptionsformatierung auf Hindi arbeiten
- Wenn der spezifische Formatierungsanforderungen nicht auf Ihren Anwendungsfall zutrifft

Bewährte Methode: Fügen Sie nur dann eine Sprachansage hinzu, wenn Sie speziell eine Hindi-Transkriptionsformatierung benötigen. Alle anderen Anweisungen — einschließlich Spracheinstellungen, Antwortstil, Ausführlichkeit und Argumentation — sollten in Ihrer Systemaufforderung enthalten sein.

Wichtig: Sprachansagen müssen nach der Systemaufforderung an das Modell gesendet werden.

Empfohlene Standard-Systemaufforderung für Spracheingabe

You are a warm, professional, and helpful AI assistant. Give accurate answers that sound natural, direct, and human. Start by answering the user's question clearly in 1-2 sentences. Then, expand only enough to make the answer understandable, staying within 3-5 short sentences total. Avoid sounding like a lecture or essay.

Konfiguration der Sprachaufforderung

Code-Umschaltung

Hinweis: Diese Funktion gilt derzeit nur für die Sprache Hindi.

Wählen Sie je nach Ihrem gewünschten Ausgabeskript eine der folgenden Eingabeaufforderungen:

Für die Ausgabe in lateinischer Schrift (romanisiertes Hindi):

If the input audio/speech contains hindi, then the transcription and response should be in All Latin script (romanized Hindi).

Für die Ausgabe von Devanagari-Skripten:

If the input audio/speech contains hindi, then the transcription and response should be in All Devanagari script (Hindi).

Für gemischte Skriptaussgabe (natürliches Code-Switching):

If the input audio/speech contains hindi, then the transcription and response can mix Latin and Devanagari scripts naturally for code-switching.

Konfiguration der Systemaufforderung

Steuerung der Ausführlichkeit der Antwort

Prägnante, dialogorientierte Antworten:

You are a warm, professional, and helpful AI assistant. Give accurate answers that sound natural, direct, and human. Start by answering the user's question clearly in 1-2 sentences. Then, expand only enough to make the answer understandable, staying within 3-5 short sentences total. Avoid sounding like a lecture or essay.

Ausführliche, gründliche Antworten:

You are a warm, professional, and helpful AI assistant. Give accurate, complete answers that sound warm, direct, and human. Answer the question directly in the first 1-2 sentences. If the question has parts or asks what/why/how, address each with a brief definition or main idea plus 2-3 key facts or steps. Offer practical, actionable advice. Keep a confident, kind, conversational tone; never robotic or theatrical. Be thorough; add examples or context only when helpful. Prefer accuracy and safety over speculation; if unsure, say so and suggest what to check.

Spiegelung der Sprache

Nova kann die Sprache, die der Benutzer spricht, erkennen und darauf reagieren. Verwenden Sie diese Aufforderung, um die Sprachkonsistenz aufrechtzuerhalten:

CRITICAL LANGUAGE MIRRORING RULES:

- Always reply in the language spoken. DO NOT mix with English. However, if the user talks in English, reply in English.
- Please respond in the language the user is talking to you in, If you have a question or suggestion, ask it in the language the user is talking in. I want to ensure that our communication remains in the same language as the user.

Geschlechtervereinbarung für geschlechtsspezifische Sprachen

In einigen Sprachen ist eine geschlechtsspezifische Vereinbarung in Verben, Adjektiven oder Pronomen erforderlich, wenn der Assistent sich selbst beschreibt. Geben Sie für diese Sprachen das Geschlecht des Assistenten in der Systemaufforderung an, damit es Ihrer ausgewählten Stimme entspricht.

Betroffene Sprachen: Hindi, Portugiesisch, Französisch, Italienisch, Spanisch, Russisch, Polnisch

Wenn Geschlechtervereinbarung wichtig ist:

- Hindi: Immer nötig — Verben werden anhand des Geschlechts des Sprechers in der ersten Person konjugiert
- Portuguese/French: Wird benötigt, wenn Partizipien oder Adjektive der Vergangenheit verwendet werden (z. B. „Ich bin müde“ — „Estou“) cansada/cansado
- Italian/Spanish: Wird benötigt, wenn Adjektive verwendet werden, um sich selbst zu beschreiben (wie „Ich bin glücklich“ — „Sono“) contenta/contento

Umsetzung:

Geben Sie zu Beginn Ihrer Systemaufforderung die entsprechende Geschlechtsidentifikation an, die auf Ihrer Sprachauswahl basiert:

Für weiblich klingende Stimmen (Kiara, Carolina, Ambre, Beatrice, Lupe, Tiffany):

You are a warm, professional, and helpful female AI assistant.

Für männlich klingende Stimmen (Arjun, Leo, Florian, Lorenzo, Carlos, Matthew):

You are a warm, professional, and helpful male AI assistant.

Beispiele:

Hindi mit weiblicher Stimme (Kiara):

You are a warm, professional, and helpful female AI assistant.

Ergebnis: „“ (Haupt-Achchhi-Hoon) gegen „“ (Haupt-Achchha-Hoon)

Italienisch mit männlicher Stimme (Lorenzo):

You are a warm, professional, and helpful male AI assistant.

Ergebnis: „Sono contento“ gegen „Sono contenta“

Gedankenkette für Speech: Verfassungsrechtliche Argumentation

Verwenden Sie diese Aufforderung, wenn das Modell seine Argumentation für komplexe Probleme zeigen soll:

You are a friendly assistant. The user will give you a problem. Explain your reasoning following the guidelines given in CONSTITUTION - REASONING, and summarize your decision at the end of your response, in one sentence.

CONSTITUTION - REASONING

1. For simple questions including simple calculations or contextual tasks: Give the answer directly. No explanation is necessary, although you can offer to provide more information if the user requests it.
2. When faced with complex problems or decisions, think through the steps systematically before providing your answer. Break down your reasoning process when it would help user understanding.
3. For subjective matters or comparisons: explain your thought process step-by-step.

Hinweis: Wenn Sie nicht möchten, dass das Modell bei jeder Anfrage eine Argumentation durchgeht, können Sie der Aufforderung ein paar kurze Beispiele hinzufügen (siehe Beispiele unten).

You are a warm, professional, and helpful AI assistant. You converse in fluid and conversational English. Give accurate, complete answers that sound warm, direct, and human. Answer the question directly in the first 1-2 sentences. Keep a confident, kind, conversational tone; never robotic or theatrical. Avoid formatted lists or numbering and keep your output as a spoken transcript. Be concise but thorough; add examples or context only when helpful. Prefer accuracy and safety over speculation; if unsure, say so and suggest what to check. The user will give you a problem.

Explain your reasoning following the guidelines given in CONSTITUTION - REASONING, and summarize your decision at the end of your response in one sentence.

CONSTITUTION - REASONING

1. When faced with complex problems or decisions, think through the steps systematically before providing your answer. Break down your reasoning process when it would help user understanding.
2. For subjective matters or comparisons: explain your thought process step-by-step.
3. For simple questions including simple calculations or contextual tasks: Give the answer directly. No explanation is necessary, although you can offer to provide more information if the user requests it.

EXAMPLES

User: What is $7 + 5$?

Assistant: 12.

User: What is the capital of India?

Assistant: Delhi is the capital of India.

User: I have a \$1,000 budget for a trip. Here are my costs... Can I afford it? Please explain your reasoning.

Assistant: (step-by-step breakdown + one-sentence conclusion)

Übermäßiger Gebrauch von vorgeschlagenen Ausdrücken

Nova Sonic 2 reagiert empfindlicher auf Phrasenvorschläge als Sonic 1. Diese erhöhte Sensitivität ist nicht von Natur aus gut oder schlecht — sie hängt von Ihrem Anwendungsfall ab. Wenn Sie eine konsistente, vorhersehbare Formulierung wünschen, kann dies von Vorteil sein. Wenn Sie jedoch eine natürlichere Variation wünschen, können explizite Ausdruckslisten zu einer übermäßigen Verwendung führen.

Wenn Sie Eingabeaufforderungen mit expliziten Ausdruckslisten verwenden, verwendet das Modell diese sehr häufig:

Beispiel 1 — Betonungsphrasen:

Instead of using bold or italics, emphasize important information by using phrases like "The key thing to remember is," "What's really important here is," or "I want to highlight that."

Beispiel 2 — Füllstoffe für Konversationen:

Include natural speech elements like "Well," "You know," "Actually," "I mean," or "By the way" at appropriate moments to create an authentic, casual conversation flow.

Empfehlung:

- Wenn Sie eine einheitliche Formulierung wünschen: Listen mit expliziten Phrasen eignen sich gut für Sonic 2, um vorhersehbare, markengerechte Antworten zu erzeugen.
- Wenn Sie natürliche Variationen wünschen: Vermeiden Sie es, explizite Phrasenlisten bereitzustellen. Verwenden Sie stattdessen allgemeine Hinweise wie „klingt natürlich und umgangssprachlich“ oder geben Sie einmalige Beispiele an.

Besserer Ansatz — Verwenden Sie einmalige Beispiele:

Anstatt Phrasen aufzulisten, geben Sie 1-2 Beispiele an, die den gewünschten Ton und Stil veranschaulichen:

Natürlicher, hilfreicher Ton

You are a warm, professional, and helpful AI assistant. Sound natural and conversational in your responses.

Example:

User: How do I reset my password?

Assistant: You can reset your password by clicking the "Forgot Password" link on the login page. You'll get an email with instructions to create a new one. The whole process usually takes just a couple of minutes.

Prägnant und direkt

You are a helpful AI assistant. Provide clear, direct answers without unnecessary elaboration.

Example:

User: What's the weather like today?

Assistant: It's 72 degrees and sunny with a light breeze. Perfect day to be outside.

Professionell mit Einfühlungsvermögen

You are a professional and empathetic AI assistant. Acknowledge the user's situation while providing practical solutions.

Example:

User: I'm frustrated because my order hasn't arrived yet.

Assistant: I understand how frustrating that must be, especially when you're waiting for something important. Let me check your order status right now. Can you provide your order number?

Technisch aber zugänglich

You are a knowledgeable AI assistant who explains technical concepts in accessible language.

Example:

User: What is machine learning?

Assistant: Machine learning is when computers learn from examples rather than following strict rules. Think of it like teaching a child to recognize dogs—after seeing many dogs, they start recognizing new ones on their own. The computer does something similar with data.


Dieser Ansatz zeigt dem Modell das gewünschte Verhalten, ohne sich wiederholende Phrasenmuster auszulösen, wobei die Kontrolle über Ton und Stil erhalten bleibt.

Schlüsselkonzepte

Amazon Nova 2 Sonic verwendet eine bidirektionale Streaming-Architektur mit strukturierten Ereignissen für Konversations-KI in Echtzeit. Das Verständnis dieser Kernkonzepte ist für die Entwicklung effektiver Sprachanwendungen unerlässlich.

Lebenszyklus eines Ereignisses

Das folgende Diagramm veranschaulicht den vollständigen Lebenszyklus eines bidirektionalen Streaming-Ereignisses:



Der Lebenszyklus eines bidirektionalen Streaming-Ereignisses folgt einem strukturierten Muster von der Sitzungsinitialisierung bis zum Abschluss der Konversation. Jede Konversation umfasst Eingabeereignisse (aus Ihrer Anwendung) und Ausgabeereignisse (aus Amazon Nova 2 Sonic), die zusammenarbeiten, um natürliche Sprachinteraktionen zu erzeugen.

Reihenfolge des Ablaufs der Ereignisse

Eine typische Konversation folgt dieser Ereignissequenz:

1. Sitzungsstart — Initialisieren Sie die Konversationssitzung
2. Systemaufforderung — Systemanweisungen senden
3. Chat-Verlauf (optional) — Geben Sie den Gesprächskontext an
4. Audio Chunks — Streamen Sie die Audioeingaben von Benutzern
5. Abschluss — Start — Die KI beginnt mit der Verarbeitung
6. ASR Transcripts (USER) — Sprachtranskription für Benutzer
7. Verwendung des Tools (optional) — KI fordert die Ausführung des Tools an
8. Werkzeughandhabung (optional) — Werkzeugergebnisse verarbeiten und zurückgeben
9. Transkript (ASSISTENT) — SPEKULATIV — Vorläufige KI-Antwort
10. Audio-Chunks — AI-Audioausgabe streamen
11. Transkript (ASSISTENT) — FINAL — Endgültiges AI-Antwortprotokoll
12. Inhalt und Audio — Kennzeichnet das Ende des Audioinhalts
13. Ende der Aufforderung — Zeigt den Abschluss der Verarbeitung der Aufforderung an
14. Sitzungsende — Schließt die Konversation

Behandlung von Eingabeereignissen mit der bidirektionalen API

Die bidirektionale Stream-API verwendet eine ereignisgesteuerte Architektur mit strukturierten Eingabe- und Ausgabeereignissen. Das Verständnis der richtigen Reihenfolge der Ereignisse ist entscheidend für die Implementierung erfolgreicher Konversationsanwendungen und die Aufrechterhaltung des richtigen Konversationsstatus während der gesamten Interaktionen.

-Übersicht

Die Nova-Sonic-Konversation folgt einer strukturierten Ereignissequenz. Sie senden zunächst ein `sessionStart`-Ereignis, das die Konfigurationsparameter der Inferenz wie Temperatur- und Token-

Grenzwerte enthält. Anschließend senden Sie `promptStart`, um das Audioausgabeformat und die Toolkonfigurationen zu definieren, und weisen eine eindeutige `promptName-ID` zu, die in allen nachfolgenden Ereignissen enthalten sein muss.

Für jeden Interaktionstyp (Systemaufforderung, Audio usw.) folgen Sie einem dreiteiligen Muster: Definieren Sie `contentStart` damit den Inhaltstyp und die Rolle des Inhalts (SYSTEM,,,SYSTEM_SPEECH) USER ASSISTANT TOOL, geben Sie dann das eigentliche Inhaltseignis an und schließen Sie mit `contentEnd` um das Segment zu schließen. Das `contentStart`-Ereignis gibt an, ob Sie Toolergebnisse, Streaming-Audio oder einen System-Prompt senden. Das `contentStart`-Ereignis enthält eine eindeutige `contentName-ID`.

Verlauf der Konversationen

Ein Konversationsverlauf kann nur einmal hinzugefügt werden, nämlich nach dem System-Prompt und bevor das Audio-Streaming beginnt. Er folgt demselben `contentStart/textInput/contentEnd`-Muster. Die Rollen USER und ASSISTANT müssen im `contentStart`-Ereignis für jede historische Nachricht definiert werden. Dies bietet einen wichtigen Kontext für die aktuelle Konversation, muss jedoch abgeschlossen sein, bevor eine neue Benutzereingabe beginnt.

Audio-Streaming

Das Audio-Streaming arbeitet mit kontinuierlicher Mikrofonabtastung. Nach dem Senden eines ersten `contentStart`, werden Audioframes (jeweils ca. 32 ms) direkt vom Mikrofon aufgenommen und mit demselben `contentName` sofort als `audioInput`-Ereignisse gesendet. Diese Audiosamples sollten in Echtzeit gestreamt werden, sobald sie aufgenommen werden, wobei die natürliche Abtastkadenz des Mikrofons während des gesamten Gesprächs beibehalten werden sollte. Alle Audioframes teilen sich einen einzigen Inhaltscontainer, bis die Konversation endet und dieser explizit geschlossen wird.

Die Sitzung wird geschlossen


Nach Beendigung oder Abbruch des Gesprächs ist es unerlässlich, alle offenen Streams ordnungsgemäß zu schließen und die Sitzung in der richtigen Reihenfolge zu beenden. Um eine Sitzung ordnungsgemäß zu beenden und Ressourcenlecks zu vermeiden, müssen Sie eine bestimmte Schlusssequenz befolgen:

- Schließen Sie alle geöffneten Audio-Streams mit dem `contentEnd`-Ereignis.
- Senden Sie ein `promptEnd`-Ereignis, das auf den Original-`promptName` verweist.

- Senden Sie das `sessionEnd`-Ereignis.

Wenn Sie eines dieser abschließenden Ereignisse überspringen, kann dies zu unvollständigen Konversationen oder verwaisten Ressourcen führen.

Diese Identifikatoren bilden eine hierarchische Struktur: Der `promptName` verbindet alle Konversationsereignisse miteinander, während jeder einzelne `contentName` die Grenzen bestimmter Inhaltsblöcke markiert. Diese Hierarchie stellt sicher, dass das Modell während der gesamten Interaktion den richtigen Kontext beibehält.



Ablauf des Eingabeereignisses

In diesem Abschnitt wird die Struktur des Ablaufs der Eingabeereignisse erläutert.

1. RequestStartEvent (Beginn der Sitzung)

Das Sitzungsstartereignis initialisiert die Konversation mit den Einstellungen für die Inferenzkonfiguration und die Erkennung von Abbiegungen.

Konfiguration der Inferenz:

- `maxTokens`: Maximale Anzahl von Token, die in der Antwort generiert werden sollen
- `topP`: Nukleus-Probenahmeparameter (0,0 bis 1,0) zur Steuerung der Zufälligkeit

- **temperature:** Steuert die Zufälligkeit bei der Generierung (0,0 bis 1,0)

Konfiguration der Abbiegerkennung: Der `endpointingSensitivity` Parameter steuert, wie schnell Nova Sonic erkennt, wenn ein Benutzer mit dem Sprechen fertig ist:

- **HIGH:** Erkennt Pausen schnell und ermöglicht so schnellere Reaktionen, kann aber dazu führen, dass langsamere Lautsprecher ausgeschaltet werden
- **MEDIUM:** Ausgewogene Empfindlichkeit für die meisten Konversationsszenarien (empfohlene Standardeinstellung)
- **LOW:** Wartet länger, bis das Ende der Rede erkannt wird. Dies ist besser für nachdenkliche oder zögernde Sprecher

```
{
  "event": {
    "sessionStart": {
      "inferenceConfiguration": {
        "maxTokens": "int",
        "topP": "float",
        "temperature": "float"
      },
      "turnDetectionConfiguration": {
        "endpointingSensitivity": "HIGH" | "MEDIUM" | "LOW"
      }
    }
  }
}
```

Beispiel:

```
{
  "event": {
    "sessionStart": {
      "inferenceConfiguration": {
        "maxTokens": 2048,
        "topP": 0.9,
        "temperature": 0.7
      },
      "turnDetectionConfiguration": {
        "endpointingSensitivity": "MEDIUM"
      }
    }
  }
}
```



```

    }
  }
}

```

2. PromptStartEvent

Das Ereignis zum Starten der Aufforderung definiert die Konversationskonfiguration, einschließlich der Ausgabeformate, der Sprachauswahl und der verfügbaren Tools.

Eine Liste der verfügbaren Sprach-IDs finden Sie unter [Sprachunterstützung und mehrsprachige Funktionen](#)

```

{
  "event": {
    "promptStart": {
      "promptName": "string", // unique identifier same across all events i.e.
      UUID
      "textOutputConfiguration": {
        "mediaType": "text/plain"
      },
      "audioOutputConfiguration": {
        "mediaType": "audio/lpcm",
        "sampleRateHertz": 8000 | 16000 | 24000,
        "sampleSizeBits": 16,
        "channelCount": 1,
        "voiceId": "matthew" | "tiffany" | "amy" | "olivia" | "lupe" | "carlos"
        | "ambre" | "florian" | "lennart" | "beatrice" | "lorenzo" |
          "tina" | "carolina" | "leo" | "kiara" | "arjun",
        "encoding": "base64",
        "audioType": "SPEECH"
      },
      "toolUseOutputConfiguration": {
        "mediaType": "application/json"
      },
      "toolConfiguration": {
        "tools": [
          {
            "toolSpec": {
              "name": "string",
              "description": "string",
              "inputSchema": {
                "json": "{}"
              }
            }
          }
        ]
      }
    }
  }
}

```

```
}
}
}
}
}
}
```

3. InputContentStartEvent

Text

Das Starterereignis für Textinhalte wird für Systemaufforderungen, den Konversationsverlauf und die modalübergreifende Texteingabe verwendet.

Interaktiver Parameter:

- **true:** Ermöglicht modalübergreifende Eingabe und ermöglicht Textnachrichten während einer aktiven Sprachsituation
- **false:** Standardtexteingabe für Systemaufforderungen und Gesprächsverlauf

Rollentypen:

- SYSTEM: Systemanweisungen und Eingabeaufforderungen
- USER: Benutzernachrichten im Konversationsverlauf oder modalübergreifende Eingabe
- ASSISTANT: Antworten des Assistenten im Konversationsverlauf
- SYSTEM_SPEECH: Steuert die Transkriptionsformatierung für die Umschaltung zwischen Hindi-Codes (Skripte) Latin/Devanagari/mixed

```
{
  "event": {
    "contentStart": {
      "promptName": "string", // same unique identifier from promptStart event
      "contentName": "string", // unique identifier for the content block
      "type": "TEXT",
      "interactive": "boolean", // true for cross-modal input
      "role": "SYSTEM" | "USER" | "ASSISTANT" | "TOOL" | "SYSTEM_SPEECH",
      "textInputConfiguration": {
        "mediaType": "text/plain"
      }
    }
  }
}
```

```

    }
  }
}

```

Beispiel — Systemaufforderung:

```

{
  "event": {
    "contentStart": {
      "promptName": "conv-12345",
      "contentName": "system-prompt-1",
      "type": "TEXT",
      "interactive": false,
      "role": "SYSTEM",
      "textInputConfiguration": {
        "mediaType": "text/plain"
      }
    }
  }
}

```

Beispiel — Cross-modal Eingabe:

```

{
  "event": {
    "contentStart": {
      "promptName": "conv-12345",
      "contentName": "user-text-1",
      "type": "TEXT",
      "interactive": true,
      "role": "USER",
      "textInputConfiguration": {
        "mediaType": "text/plain"
      }
    }
  }
}

```

Audio

```

{

```

```

    "event": {
      "contentStart": {
        "promptName": "string", // same unique identifier from promptStart event
        "contentName": "string", // unique identifier for the content block
        "type": "AUDIO",
        "interactive": true,
        "role": "USER",
        "audioInputConfiguration": {
          "mediaType": "audio/lpcm",
          "sampleRateHertz": 8000 | 16000 | 24000,
          "sampleSizeBits": 16,
          "channelCount": 1,
          "audioType": "SPEECH",
          "encoding": "base64"
        }
      }
    }
  }
}

```

Tool

```

{
  "event": {
    "contentStart": {
      "promptName": "string", // same unique identifier from promptStart event
      "contentName": "string", // unique identifier for the content block
      "interactive": false,
      "type": "T00L",
      "role": "T00L",
      "toolResultInputConfiguration": {
        "toolUseId": "string", // existing tool use id
        "type": "TEXT",
        "textInputConfiguration": {
          "mediaType": "text/plain"
        }
      }
    }
  }
}

```

4. TextInputContent

```

{

```

```
"event": {
  "textInput": {
    "promptName": "string", // same unique identifier from promptStart event
    "contentName": "string", // unique identifier for the content block
    "content": "string"
  }
}
```

5. AudioInputContent

```
{
  "event": {
    "audioInput": {
      "promptName": "string", // same unique identifier from promptStart event
      "contentName": "string", // same unique identifier from its contentStart
      "content": "base64EncodedAudioData"
    }
  }
}
```

6. ToolResultContentEvent

```
"event": {
  "toolResult": {
    "promptName": "string", // same unique identifier from promptStart event
    "contentName": "string", // same unique identifier from its contentStart
    "content": "{\"key\": \"value\"}" // stringified JSON object as a tool result
  }
}
```

7. InputContentEndEvent

```
{
  "event": {
    "contentEnd": {
      "promptName": "string", // same unique identifier from promptStart event
      "contentName": "string" // same unique identifier from its contentStart
    }
  }
}
```

8. PromptEndEvent

```
{
  "event": {
    "promptEnd": {
      "promptName": "string" // same unique identifier from promptStart event
    }
  }
}
```

9. RequestEndEvent

```
{
  "event": {
    "sessionEnd": {}
  }
}
```

Ausgabeereignisse mit der bidirektionalen API behandeln

Wenn das Amazon-Nova-Sonic-Modell antwortet, folgt es einer strukturierten Ereignissequenz. Der Ablauf beginnt mit einem `completionStart`-Ereignis, das eindeutige Identifikatoren wie `sessionId`, `promptName` und `completionId` enthält. Diese Identifikatoren sind während des gesamten Antwortzyklus konsistent und vereinen alle nachfolgenden Reaktionsereignisse.

-Übersicht

Jeder Antworttyp folgt einem konsistenten dreiteiligen Muster: `contentStart` definiert den Inhaltstyp und das Format, das eigentliche Inhaltsereignis und `contentEnd` schließt dieses Segment. Die Antwort umfasst in der Regel mehrere aufeinanderfolgende Inhaltsblöcke: Transkription mittels automatischer Spracherkennung (ASR) (was der Benutzer gesagt hat), optionale Verwendung von Tools (wenn externe Informationen benötigt werden), Textantwort (was das Modell zu sagen plant) und Audioantwort (die gesprochene Ausgabe).

Inhaltstypen für Antworten

ASR-Transkription

Die ASR-Transkription erscheint zuerst und vermittelt das Verständnis des Modells für die Sprache des Benutzers mit `role: "USER"` und `"additionalModelFields": "{ \"generationStage\": \"FINAL\" }"` in `contentStart`.

Verwendung des Tools

Wenn das Modell externe Daten benötigt, sendet es Tool-bezogene Ereignisse mit bestimmten Tool-Namen und -Parametern.

Textantwort

Die Textantwort bietet eine Vorschau des geplanten Sprachbeitrags mit `role: "ASSISTANT"` und `"additionalModelFields": "{\\"generationStage\\":\\"SPECULATIVE\\"}"`.

Audioantwort

Die Audioantwort liefert dann Base64-kodierte Sprachblöcke, die im gesamten Stream dieselbe `contentId` verwenden.

Barge-In Support

Während der Audiogenerierung unterstützt Amazon Nova Sonic durch seine Barge-In-Funktion den natürlichen Gesprächsfluss. Wenn ein Benutzer Amazon Nova Sonic unterbricht, während es spricht, stoppt Nova Sonic sofort die Sprachgenerierung, wechselt in den Hörmodus und sendet eine Inhaltsbenachrichtigung, die darauf hinweist, dass die Unterbrechung aufgetreten ist. Da Nova Sonic schneller als in Echtzeit arbeitet, wurden einige Audiodaten möglicherweise bereits übertragen, aber noch nicht abgespielt. Die Unterbrechungsbenachrichtigung ermöglicht es der Client-Anwendung, ihre Audiowarteschlange zu löschen und die Wiedergabe sofort zu beenden, wodurch ein responsives Konversationserlebnis entsteht.

Endgültige Transkription

Nachdem die Audiogenerierung abgeschlossen ist (oder per Barge-In unterbrochen wurde), bietet Amazon Nova Sonic eine zusätzliche Textantwort, die eine Transkription des tatsächlich Gesprochenen auf Satzebene enthält. Diese Textantwort beinhaltet ein `contentStart`-Ereignis mit `role: "ASSISTANT"` und `"additionalModelFields": "{\\"generationStage\\":\\"FINAL\\"}"`.

Nachverfolgung der Nutzung


Während der gesamten Antwortverarbeitung werden `usageEvent`-Ereignisse gesendet, um den Token-Verbrauch zu verfolgen. Diese Ereignisse enthalten detaillierte Metriken zu Eingabe- und Ausgabetoken (sowohl Sprache als auch Text) sowie deren kumulierte Gesamtwerte. Jedes `usageEvent`-Ereignis behält dieselben `sessionId`, `promptName` und `completionId` wie andere Ereignisse im Konversationsablauf bei. Der Abschnitt „Details“ enthält sowohl inkrementelle

Änderungen (Delta) als auch laufende Summen der Token-Verwendung, wodurch eine genaue Überwachung der Verwendung während der Konversation ermöglicht wird.

Abschluss

Das Modell sendet ein `completionEnd`-Ereignis mit den ursprünglichen Kennungen und einem `stopReason`, der angibt, wie die Konversation endete. Diese Ereignishierarchie stellt sicher, dass Ihre Anwendung nachverfolgen kann, welche Teile der Antwort zusammengehören, und diese entsprechend verarbeiten kann, wobei der Konversationskontext über mehrere Gesprächsrunden hinweg beibehalten wird.

Der Ablauf der Ausgabeereignisse beginnt mit dem Eintritt in die Phase der Antwortgenerierung. Er beginnt mit der automatischen Spracherkennung, wählt ein zu verwendendes Tool aus, transkribiert Sprache, generiert Audio, schließt die Transkription ab und beendet die Sitzung.



Ablauf der Ausgabeereignisse

In diesem Abschnitt wird die Struktur des Ausgabe-Ereignisflusses beschrieben.

1. UsageEvent

```

"event": {
  "usageEvent": {
    "completionId": "string", // unique identifier for completion
    "details": {
      "delta": { // incremental changes since last event
        "input": {
          "speechTokens": number, // input speech tokens
          "textTokens": number // input text tokens
        },

```



```

        "output": {
            "speechTokens": number, // speech tokens generated
            "textTokens": number // text tokens generated
        },
        "total": { // cumulative counts
            "input": {
                "speechTokens": number, // total speech tokens processed
                "textTokens": number // total text tokens processed
            },
            "output": {
                "speechTokens": number, // total speech tokens generated
                "textTokens": number // total text tokens generated
            }
        },
        "promptName": "string", // same unique identifier from promptStart event
        "sessionId": "string", // unique identifier
        "totalInputTokens": number, // cumulative input tokens
        "totalOutputTokens": number, // cumulative output tokens
        "totalTokens": number // total tokens in the session
    }
}

```

2. CompleteStartEvent

```

"event": {
    "completionStart": {
        "sessionId": "string", // unique identifier
        "promptName": "string", // same unique identifier from promptStart event
        "completionId": "string", // unique identifier
    }
}

```

3. TextOutputContent

ContentStart

```

"event": {
    "contentStart": {
        "additionalModelFields": "{\\"generationStage\\":\\"FINAL\\"}" |
        "{\\"generationStage\\":\\"SPECULATIVE\\"}",
        "sessionId": "string", // unique identifier
    }
}

```

```

    "promptName": "string", // same unique identifier from promptStart event
    "completionId": "string", // unique identifier
    "contentId": "string", // unique identifier for the content block
    "type": "TEXT",
    "role": "USER" | "ASSISTANT",
    "textOutputConfiguration": {
        "mediaType": "text/plain"
    }
  }
}

```

TextOutput

```

"event": {
  "textOutput": {
    "sessionId": "string", // unique identifier
    "promptName": "string", // same unique identifier from promptStart event
    "completionId": "string", // unique identifier
    "contentId": "string", // same unique identifier from its contentStart
    "content": "string" // User transcribe or Text Response
  }
}

```

ContentEnd

```

"event": {
  "contentEnd": {
    "sessionId": "string", // unique identifier
    "promptName": "string", // same unique identifier from promptStart event
    "completionId": "string", // unique identifier
    "contentId": "string", // same unique identifier from its contentStart
    "stopReason": "PARTIAL_TURN" | "END_TURN" | "INTERRUPTED",
    "type": "TEXT"
  }
}

```

4. ToolUse

ContentStart

```

"event": {
  "contentStart": {
    "sessionId": "string", // unique identifier

```

```

    "promptName": "string", // same unique identifier from promptStart event
    "completionId": "string", // unique identifier
    "contentId": "string", // unique identifier for the content block
    "type": "T00L",
    "role": "T00L",
    "toolUseOutputConfiguration": {
        "mediaType": "application/json"
    }
  }
}

```

ToolUse

```

"event": {
  "toolUse": {
    "sessionId": "string", // unique identifier
    "promptName": "string", // same unique identifier from promptStart event
    "completionId": "string", // unique identifier
    "contentId": "string", // same unique identifier from its contentStart
    "content": "json",
    "toolName": "string",
    "toolUseId": "string"
  }
}

```

ContentEnd

```

"event": {
  "contentEnd": {
    "sessionId": "string", // unique identifier
    "promptName": "string", // same unique identifier from promptStart event
    "completionId": "string", // unique identifier
    "contentId": "string", // same unique identifier from its contentStart
    "stopReason": "T00L_USE",
    "type": "T00L"
  }
}

```

5. AudioOutputContent

ContentStart

```

"event": {

```

```

    "contentStart": {
      "sessionId": "string", // unique identifier
      "promptName": "string", // same unique identifier from promptStart event
      "completionId": "string", // unique identifier
      "contentId": "string", // unique identifier for the content block
      "type": "AUDIO",
      "role": "ASSISTANT",
      "audioOutputConfiguration": {
        "mediaType": "audio/lpcm",
        "sampleRateHertz": 8000 | 16000 | 24000,
        "sampleSizeBits": 16,
        "encoding": "base64",
        "channelCount": 1
      }
    }
  }
}

```

AudioOutput

```

"event": {
  "audioOutput": {
    "sessionId": "string", // unique identifier
    "promptName": "string", // same unique identifier from promptStart event
    "completionId": "string", // unique identifier
    "contentId": "string", // same unique identifier from its contentStart
    "content": "base64EncodedAudioData", // Audio
  }
}

```

ContentEnd

```

"event": {
  "contentEnd": {
    "sessionId": "string", // unique identifier
    "promptName": "string", // same unique identifier from promptStart event
    "completionId": "string", // unique identifier
    "contentId": "string", // same unique identifier from its contentStart
    "stopReason": "PARTIAL_TURN" | "END_TURN",
    "type": "AUDIO"
  }
}

```


6. CompletionEndEvent

```
"event": {
  "completionEnd": {
    "sessionId": "string", // unique identifier
    "promptName": "string", // same unique identifier from promptStart event
    "completionId": "string", // unique identifier
    "stopReason": "END_TURN"
  }
}
```

Barge-in

Barge-in ermöglicht es Benutzern, den KI-Assistenten zu unterbrechen, während er spricht, genau wie bei natürlichen menschlichen Gesprächen. Anstatt darauf zu warten, dass der Assistent fertig ist, können Benutzer neue Informationen eingeben, ihre vorherige Aussage korrigieren oder klarstellen, die Konversation auf ein anderes Thema umleiten oder den Assistenten einfach beenden, wenn sie genug gehört haben. Dies sorgt für ein natürlicheres und reaktionsschnelleres Konversationserlebnis.

Das folgende Diagramm veranschaulicht den gesamten Gesprächsablauf:



So geht Amazon Nova 2 Sonic mit Barge-In um

Amazon Nova 2 Sonic ist so konzipiert, dass es problemlos mit Unterbrechungen umgeht. Wenn der Benutzer während einer Antwort zu sprechen beginnt, beendet das System sofort die Generierung der aktuellen Antwort, behält den vollständigen Konversationskontext bei, sendet ein Unterbrechungssignal an den Client und beginnt mit der Verarbeitung der neuen Benutzereingabe.

Kontexterhaltung: Selbst bei einer Unterbrechung erinnert sich Nova Sonic an das, was vor der Unterbrechung gesagt wurde, an das besprochene Thema, den Gesprächsverlauf und an jeden relevanten Kontext aus früheren Runden. Dadurch wird sichergestellt, dass die Konversation kohärent und natürlich bleibt.

Client-side Anforderungen an die Umsetzung

Amazon Nova 2 Sonic kümmert sich zwar serverseitig um Barge-In, aber Sie müssen für ein vollständiges Erlebnis die clientseitige Logik implementieren.

Die Herausforderung bei der Audiowarteschlange: Die Audiogenerierung ist schneller als die Wiedergabegeschwindigkeit. Das bedeutet Folgendes:

- Nova Sonic generiert schnell Audioblöcke
- Ihr Kunde empfängt diese Chunks und stellt sie in die Warteschlange
- Der Kunde spielt sie mit normaler Sprechgeschwindigkeit ab
- Wenn ein Barge-In auftritt, befindet sich der Ton bereits in der Warteschlange für die Wiedergabe

Erforderliche clientseitige Logik: Ihre Anwendung muss vier wichtige Schritte ausführen:

1. Erkennen Sie das Unterbrechungssignal: Achten Sie auf das Unterbrechungseignis von Nova Sonic und reagieren Sie sofort, wenn es empfangen wird.
2. Aktuelle Wiedergabe beenden: Unterbrechen Sie die aktuelle Audiowiedergabe und beenden Sie alle Audiodateien, die sich während der Wiedergabe befinden.
3. Audiowarteschlange löschen: Entferne alle Audioblöcke in der Warteschlange und verwirfe alle gepufferten Audiodateien aus der unterbrochenen Antwort.
4. Neues Audio starten: Beginnt mit der Wiedergabe des neu empfangenen Audios und setzt den normalen Wiedergabefluss fort.

Turn-taking Steuerbarkeit

Turn-taking ist ein grundlegender Aspekt natürlicher Konversation. Amazon Nova 2 Sonic bietet eine genaue Kontrolle darüber, wann die KI an der Reihe ist, über den `DetectionConfiguration` Turn-Parameter zu sprechen. Auf diese Weise können Sie den Gesprächsfluss für verschiedene Anwendungsfälle optimieren und dabei Reaktionsfähigkeit und Genauigkeit in Einklang bringen. Der Parameter `EndpointingSensitivity` steuert, wie schnell Amazon Nova 2 Sonic das Ende der Runde eines Benutzers erkennt und zu reagieren beginnt. Diese Einstellung wirkt sich sowohl auf die Latenz der Antworten als auch auf die Wahrscheinlichkeit aus, dass Benutzer, die noch sprechen, unterbrochen werden.

API-Konfiguration

Konfigurieren Sie die Empfindlichkeit bei der Erkennung von Zugängen im `SessionStart`-Ereignis:

```
{
  "event": {
    "sessionStart": {
      "inferenceConfiguration": {
        "maxTokens": 1000,
        "topP": 0.9,
        "temperature": 0.7
      },
      "turnDetectionConfiguration": {
        "endpointingSensitivity": "HIGH" | "MEDIUM" | "LOW"
      }
    }
  }
}
```

Empfindlichkeitsstufen

Der Parameter `EndPointingSensitivity` akzeptiert drei Werte: `HIGH`, `MEDIUM` und `LOW`. Bei jeder Stufe wird die Reaktionsgeschwindigkeit gegen das Risiko abgewogen, dass Benutzer, die noch sprechen, unterbrochen werden.

HIGH (HOCH)

Schnellste Reaktionszeit, optimiert für Latenz. Nova Sonic reagiert so schnell wie möglich, nachdem das Ende der Sprache erkannt wurde. Dauer der Pause: 1,5 Sekunden. Ideal für

schnelle Fragen und Antworten, Befehls- und Steuerungsanwendungen und zeitkritische Interaktionen.

MITTEL

Ausgewogener Ansatz mit moderater Reaktionszeit. Reduziert Fehlalarme bei gleichbleibender Reaktionsfähigkeit. Dauer der Pause: 1,75 Sekunden. Ideal für allgemeine Gespräche, Kundenservice mit komplexen Fragen und Diskussionen mit mehreren Runden.

NIEDRIG

Langsamste Reaktionszeit mit maximaler Geduld. Nova Sonic wartet am längsten, bevor es reagiert, wodurch Unterbrechungen durch Benutzer, die beim Nachdenken innehalten, minimiert werden. Dauer der Pause: 2 Sekunden. Ideal für durchdachte Gespräche, ältere oder sprachbehinderte Benutzer und zur Lösung komplexer Probleme.

Referenz für die Dauer der Pause

Empfindlichkeitsstufe	Dauer der Pause (Sekunden)
Hoch (schnell)	1.5
Mittel	1,75
Niedrig (langsam)	~2,0

Cross-modal Eingabe

Amazon Nova 2 Sonic unterstützt jetzt modalübergreifende Eingaben, sodass Sie während einer Konversationssitzung zusätzlich zur Spracheingabe Textnachrichten senden können. Sprache bleibt zwar die primäre Art der Interaktion, aber die Texteingabe bietet Flexibilität in Szenarien, in denen das Tippen bequemer oder angemessener ist.

Kontinuierliches Streaming erforderlich: Die Cross-modal Eingabe erfordert eine aktive Streaming-Sitzung, um ordnungsgemäß zu funktionieren. Die Sitzung muss wie bei einer normalen Sprachsitzung kontinuierlich gestreamt werden, andernfalls werden Standard-Sitzungs-Timeouts angewendet und die Verbindung wird beendet.

Sensitivitätsstufen bei modalübergreifender Texteingabe sind nützlich für Szenarien wie:

- **Client-side App-Integration (Web und Mobile):** Ermöglicht Benutzern die Interaktion mit der Anwendung sowohl über Text als auch über Sprache und unterstützt so ein nahtloses multimodales Erlebnis.
- **Anwendungsfall:** Unmittelbar nach Beginn der Sitzung kann eine Textnachricht gesendet werden, die das Model auffordert, mit dem Sprechen zu beginnen. Model-start-first
- **Anleitung des Modells beim asynchronen Werkzeugaufruf:** Wenn ein ToolUse-Ereignis ausgelöst wird und das System mit der Verarbeitung von Toolaufrufen beginnt, kann der Kunde eine Textnachricht an Sonic senden, um während der Wartezeit eine natürliche Antwort zu geben — zum Beispiel: „Moment mal, während ich Ihre Informationen verarbeite. Kann ich in der Zwischenzeit mit etwas anderem weiterhelfen?“
- **Telefonie-DTMF-Integration:** Der Kunde verwendet die Telefontastatur, um vertrauliche Informationen (wie Kreditkartennummern) einzugeben. Hinweis: Amazon Nova Sonic verarbeitet DTMF-Töne nicht nativ. Um die DTMF-Eingabe zu unterstützen, muss Ihr System die Töne erkennen, sie in Text umwandeln (z. B. „1234“) und an Nova 2 Sonic senden.

Funktionsweise

Cross-modal Bei der Eingabe wird eine Sequenz mit drei Ereignissen verwendet, die der Audioeingabe ähnelt:

1. **Inhalts-Startereignis:** Signalisiert den Beginn der Texteingabe
2. **Texteingabeereignis:** Enthält die eigentliche Textnachricht
3. **Ereignis am Ende des Inhalts:** Signalisiert den Abschluss der Texteingabe

Alle drei Ereignisse müssen denselben PromptName und denselben ContentName verwenden, um die Reihenfolge beizubehalten. Jedes Mal, wenn Sie eine Texteingabe senden, sollte für ContentName eine neue UUID generiert werden, um eine korrekte Nachverfolgung von Konversationen in mehreren Runden zu gewährleisten.

Ereignisstruktur

1. Ereignis zum Starten von Inhalten

Initiiert die Texteingabesequenz mit Konfigurationsdetails:

```
{  
  "event": {
```

```

    "contentStart": {
      "promptName": "<prompt_name>",
      "contentName": "<new_content_name>",
      "role": "USER",
      "type": "TEXT",
      "interactive": true,
      "textInputConfiguration": {
        "mediaType": "text/plain"
      }
    }
  }
}

```

Hauptparameter:

- **promptName**: Initiiert die Texteingabesequenz mit Konfigurationsdetails: ----SEP----:Der Name Ihrer Konversationsaufforderung (während der gesamten Sitzung einheitlich)
- **contentName**: Eine eindeutige Kennung für diese Texteingabe (generieren Sie für jede Nachricht eine neue UUID)
- **role**: Wird auf gesetzt, "USER" um Benutzereingaben anzuzeigen
- **type**: Auf "TEXT" für Texteingabe setzen
- **interactive**: Auf einstellen, true um den interaktiven Modus zu aktivieren
- **mediaType**: Auf "text/plain" für reinen Textinhalt setzen

2. Texteingabe-Ereignis

Enthält den eigentlichen Inhalt der Textnachricht:

```

{
  "event": {
    "textInput": {
      "promptName": "<prompt_name>",
      "contentName": "<new_content_name>",
      "content": "<your_text_message>"
    }
  }
}

```

Hauptparameter:

- **promptName**: Muss mit dem Wert von Content Start Event übereinstimmen
- **contentName**: Muss mit dem Wert von Content Start Event übereinstimmen
- **role**: Ihre Textnachrichten-Zeichenfolge

3. Inhalt: Veranstaltung beenden

Signalisiert den Abschluss der Texteingabe:

```
{
  "event": {
    "contentEnd": {
      "promptName": "<prompt_name>",
      "contentName": "<new_content_name>"
    }
  }
}
```

Hauptparameter:

- **promptName**: Muss mit dem Wert früherer Ereignisse übereinstimmen
- **contentName**: Muss mit dem Wert früherer Ereignisse übereinstimmen

Sprachunterstützung und mehrsprachige Funktionen

Amazon Nova 2 Sonic bietet eine vielfältige Auswahl an Stimmen in mehreren Sprachen, sodass Sie Konversations-KI-Anwendungen erstellen können, die sich für Ihre Benutzer natürlich und kulturell angemessen anfühlen. Jede Sprache bietet sowohl weiblich als auch männlich klingende Sprachoptionen.

In der folgenden Tabelle sind alle verfügbaren Stimmen und die entsprechenden Sprachumgebungen aufgeführt:

Sprache	Gebietsschema	Feminine-sounding Sprach-ID	Masculine-sounding Sprach-ID
Englisch (USA)	en-US	tiffany	matthew
Englisch (UK)	en-GB	amy	-

Sprache	Gebietsschema	Feminine-sounding Sprach-ID	Masculine-sounding Sprach-ID
Englisch (Australien)	en-AU	Olivia	-
Englisch (indisch)	en-IN	Kiara	Arjun
Französisch	fr-FR	ambre	florian
Italienisch	it-IT	beatrice	lorenzo
Deutsch	de-DE	Tina	lennart
Spanisch (USA)	es-US	lupe	carlos
Portugiesisch	pt-BR	Carolina	Löwe
Hindi	hi-IN	Kiara	Arjun

Veranstaltungsstruktur mithilfe von Stimmen in Ihrer Anwendung

Sie können die Sprach-ID angeben, `audioOutputConfiguration` wenn Sie eine Aufforderung in der `promptStart` Veranstaltung starten:

```
"event": {
  "promptStart": {
    "promptName": "string",
    "audioOutputConfiguration": {
      "mediaType": "audio/lpcm",
      "sampleRateHertz": 16000,
      "sampleSizeBits": 16,
      "channelCount": 1,
      "voiceId": "tiffany",
      "encoding": "base64",
      "audioType": "SPEECH"
    }
  }
}
```

Mehrsprachiger Support

Amazon Nova 2 Sonic bietet leistungsstarke mehrsprachige Funktionen, die natürliche Konversationen in mehreren Sprachen ermöglichen. Der Service unterstützt sowohl polyglotte Stimmen (mehrere Sprachen sprechen) als auch Code-Switching (Mischen von Sprachen innerhalb eines Satzes), sodass Sie wirklich globale Konversationsanwendungen erstellen können.

TIFFANY (en-US, weiblich) und MATTHEW (en-US, männlich) sind einzigartige polyglotte Stimmen, die alle unterstützten Sprachen sprechen können:

1. Englisch
2. Französisch
3. Italienisch
4. Deutsch
5. Spanisch
6. Portugiesisch
7. Hindi

Das macht Tiffany und Matthew ideal für Anwendungen, die nahtlos zwischen mehreren Sprachen wechseln müssen.

Verwaltung des Chat-Verlaufs


Die Antworten von Amazon Nova 2 Sonic enthalten ASR-Transkripte (Automatic Speech Recognition) für Benutzer- und Assistentenstimmen. Das Speichern des Chat-Verlaufs ist eine bewährte Methode — nicht nur zur Protokollierung, sondern auch zur Wiederaufnahme von Sitzungen, wenn die Verbindung unerwartet unterbrochen wird. Auf diese Weise kann der Client den Kontext an Nova Sonic zurücksenden, um die Konversation nahtlos fortzusetzen.

Weitere Informationen zur Verwaltung des Chat-Verlaufs finden Sie in den folgenden Ressourcen:

1. [Protokollierung des Chat-Verlaufs](#)
2. [Konversationen wieder aufnehmen](#)

Chat-Verlauf wird gesendet

Ein Konversationsverlauf kann nur einmal hinzugefügt werden, und zwar nach der system/speech Aufforderung und bevor das Audio-Streaming beginnt. Der gesamte Chatverlauf darf nicht größer als 40 KB sein. Das folgende Diagramm zeigt, wann der Chat-Verlauf während des Event-Lebenszyklus weitergegeben wird:



Für jede historische Nachricht sind drei Ereignisse erforderlich: `contentStart`, `textInput` und `contentEnd`.

Ereignisschema pro Nachricht:

- `contentStart`- Definiert die Rolle und Konfiguration der Nachricht

```
{
  "event": {
    "contentStart": {
      "promptName": "<prompt-id>",
      "contentName": "<content-id>",
      "type": "TEXT",
      "interactive": true,
      "role": "ASSISTANT",
      "textInputConfiguration": {
        "mediaType": "text/plain"
      }
    }
  }
}
```

- `textInput`- Enthält den eigentlichen Nachrichteninhalt. Ein `TextInput` darf nicht größer als 1 KB sein. Wenn ja, teilen Sie es in mehrere `TextInputs` im selben Inhaltsblock auf. Wenn die Konversation größer als 40 KB ist, kürzen Sie den gesamten Chat-Verlauf.

```
{
  "event": {
    "textInput": {
      "promptName": "<prompt-id>",
      "contentName": "<content-id>",
      "content": "Take your time, Don. I'll be here when you're ready."
    }
  }
}
```

- `contentEnd`- Markiert das Ende der Nachricht

```
{
  "event": {
    "contentEnd": {
      "promptName": "<prompt-id>",
      "contentName": "<content-id>"
    }
  }
}
```



```
}  
}  
}
```

Wiederhole diese drei Ereignisse für jede Nachricht in deinem Chat-Verlauf, wobei du zwischen den Rollen USER und ASSISTANT wechselst.

Wichtige Überlegungen:

- Der Chat-Verlauf kann nur einmal pro Sitzung aufgenommen werden
- Der Chat-Verlauf muss nach der Systemaufforderung und vor Beginn des Audio-Streamings gesendet werden
- Alle historischen Nachrichten müssen gesendet werden, bevor das Audio-Streaming gestartet wird
- In jeder Nachricht muss entweder die Rolle USER oder ASSISTANT angegeben werden
- Verwenden Sie den gespeicherten Transkriptinhalt von TextOutput-Ereignissen als Inhaltswert in TextInput

Empfangen von ASR-Transkripten

Während einer Konversation sendet Amazon Nova 2 Sonic ASR-Transkripte über Ausgabeereignisse. Jedes Transkript wird als Folge von drei Ereignissen übermittelt: contentStart, textOutput und contentEnd.

Beispiel: Sprachtranskript des Benutzers:

1. contentStart — Zeigt den Beginn eines Transkripts an:

```
{  
  "event": {  
    "contentStart": {  
      "additionalModelFields": "{\"generationStage\":\"FINAL\"}",  
      "completionId": "<completion-id>",  
      "contentId": "<content-id>",  
      "promptName": "<prompt-id>",  
      "role": "USER",  
      "sessionId": "<session-id>",  
      "textOutputConfiguration": {  
        "mediaType": "text/plain"  
      },  
    },  
  },  
}
```

```
    "type": "TEXT"
  }
}
```

2. TextOutput — Enthält den eigentlichen Inhalt des Transkripts:

```
{
  "event": {
    "textOutput": {
      "completionId": "<completion-id>",
      "content": "hello how are you",
      "contentId": "<content-id>",
      "promptName": "<prompt-id>",
      "role": "USER",
      "sessionId": "<session-id>"
    }
  }
}
```

3. contentEnd — Markiert das Ende des Transkripts:

```
{
  "event": {
    "contentEnd": {
      "completionId": "<completion-id>",
      "contentId": "<content-id>",
      "promptName": "<prompt-id>",
      "sessionId": "<session-id>",
      "stopReason": "PARTIAL_TURN",
      "type": "TEXT"
    }
  }
}
```

Das gleiche Muster aus drei Ereignissen gilt sowohl für die Rollen USER als auch für ASSISTANT. Extrahieren Sie das `content` Feld aus dem `textOutput` Ereignis und das `role` Feld aus dem `contentStart` Ereignis, um Ihren Chat-Verlauf zu erstellen.

Best Practices

Speichere den Chat-Verlauf immer, um Folgendes zu aktivieren:

- Wiederaufnahme von Sitzungen auf verschiedenen Geräten
- Protokollierung und Prüfung von Konversationen
- Erhaltung des Kontextes für nachfolgende Interaktionen

Wichtig: Verwenden Sie beim Speichern des Chat-Verlaufs Textausgaben, die auf ihrer `GenerationStage` basieren:

- **Spekulativ** — Eine Vorschau dessen, was Nova 2 Sonic zu sagen gedenkt, generiert vor Beginn der Audiosynthese
- **Finale** — Die tatsächliche Transkription dessen, was in der Audioantwort gesprochen wurde, auf Satzebene

Speichern Sie die **ENDGÜLTIGE** Textausgabe immer in Ihrem Chat-Verlauf, da sie die genaue Aufzeichnung der Konversation darstellt.

Beispiel für eine **ENDGÜLTIGE** Ausgabe (speichern Sie diese im Chat-Verlauf):

```
ContentStart event: {
  "additionalModelFields": "{\"generationStage\":\"FINAL\"}",
  "completionId": "<completion-id>",
  "contentId": "<content-id>",
  "role": "ASSISTANT",
  "sessionId": "<session-id>",
  "type": "TEXT"
}
```

Beispiel für eine **SPEKULATIVE** Ausgabe (optionale Vorschau, nicht für den Verlauf):

```
ContentStart event: {
  "additionalModelFields": "{\"generationStage\":\"SPECULATIVE\"}",
  "completionId": "<completion-id>",
  "contentId": "<content-id>",
  "role": "ASSISTANT",
  "sessionId": "<session-id>",
  "type": "TEXT"
}
```

Konfiguration des Tools


Amazon Nova 2 Sonic unterstützt die Verwendung von Tools (auch bekannt als Funktionsaufruf), sodass das Modell während Konversationen externe Informationen oder Aktionen anfordern kann, z. B. API-Aufrufe, Datenbankabfragen oder benutzerdefinierte Codefunktionen. Auf diese Weise kann Ihr Sprachassistent auf der Grundlage von Benutzeranfragen Aktionen ergreifen, Informationen abrufen und externe Dienste integrieren.

Nova 2 Sonic bietet asynchrone Werkzeuganrufe, sodass die KI weiterhin auf natürliche Weise kommunizieren kann, während die Tools im Hintergrund ausgeführt werden. Dies sorgt für ein flüssigeres und reaktionsschnelleres Benutzererlebnis.

Im Folgenden finden Sie vereinfachte Schritte zur Verwendung von Tools:

1. Tools definieren: Geben Sie die verfügbaren Tools mit ihren Parametern im PromptStart-Ereignis an
2. Der Benutzer spricht: Der Benutzer stellt eine Anfrage, für die ein Tool erforderlich ist (z. B. „Wie ist das Wetter in Seattle?“)
3. Aufruf des Tools: Nova 2 Sonic erkennt den Bedarf und sendet ein ToolUse-Ereignis
4. Tool ausführen: Ihre Anwendung führt das Tool aus und gibt Ergebnisse zurück
5. Generierung von Antworten: Nova 2 Sonic integriert die Ergebnisse in seine gesprochene Antwort

Das folgende Diagramm veranschaulicht, wie die Verwendung des Tools funktioniert:



Tools definieren

Tools werden mithilfe eines JSON-Schemas definiert, das ihren Zweck, ihre Parameter und die erwarteten Eingaben beschreibt.

Im Folgenden finden Sie Komponenten und Erläuterungen zur Tooldefinition:

- **Name:** Eindeutiger Bezeichner für das Tool (verwenden Sie `snake_case`)
- **Beschreibung:** Klare Erklärung, was das Tool macht; hilft der KI bei der Entscheidung, wann es verwendet werden soll
- **InputSchema:** JSON-Schema, das die Parameter definiert, die das Tool akzeptiert
- **Eigenschaften:** Einzelne Parameter mit Typen und Beschreibungen
- **Erforderlich:** Array von Parameternamen, die angegeben werden müssen

Beispiel für eine Werkzeugdefinition

Hier ist eine einfache Definition eines Wetter-Tools

```
{
  "toolSpec": {
    "name": "get_weather",
    "description": "Get current weather information for a specific location",
    "inputSchema": {
      "json": {
        "type": "object",
        "properties": {
          "location": {
            "type": "string",
            "description": "City name or zip code"
          },
          "units": {
            "type": "string",
            "enum": ["celsius", "fahrenheit"],
            "description": "Temperature units"
          }
        },
        "required": ["location"]
      }
    }
  }
}
```

```
}
```

Tools konfigurieren in PromptStart

Die Werkzeugkonfiguration wird in diesem promptStart Fall zusammen mit den Audio- und Textausgabeeinstellungen an Nova 2 Sonic übergeben:

```
{
  "event": {
    "promptStart": {
      "promptName": "<prompt-id>",
      "textOutputConfiguration": {
        "mediaType": "text/plain"
      },
      "audioOutputConfiguration": {
        "mediaType": "audio/lpcm",
        "sampleRateHertz": 16000,
        "sampleSizeBits": 16,
        "channelCount": 1,
        "voiceId": "matthew",
        "encoding": "base64",
        "audioType": "SPEECH"
      },
      "toolUseOutputConfiguration": {
        "mediaType": "application/json"
      },
      "toolConfiguration": {
        "tools": [
          {
            "toolSpec": {
              "name": "get_weather",
              "description": "Get current weather information for a
specific location",
              "inputSchema": {
                "json": {
                  "type": "object",
                  "properties": {
                    "location": {
                      "type": "string",
                      "description": "City name or zip code"
                    },
                    "units": {
                      "type": "string",
```

```

        "enum": ["celsius", "fahrenheit"],
        "description": "Temperature units"
      },
    ],
    "required": ["location"]
  },
  "toolChoice": {
    "auto": {}
  }
}

```

Parameter für die Werkzeugauswahl

Nova 2 Sonic unterstützt drei Werkzeugauswahlparameter, mit denen Sie steuern können, wann und welche Werkzeuge verwendet werden. Geben Sie den ToolChoice-Parameter in Ihrer Werkzeugkonfiguration an:

- **Auto (Standard):** Das Modell entscheidet, ob Werkzeuge benötigt werden, und kann bei Bedarf mehrere Tools aufrufen. Bietet maximale Flexibilität.
- **Beliebig:** Stellt sicher, dass zu Beginn der Antwort mindestens eines der verfügbaren Tools aufgerufen wird, wobei das Modell das geeignetste auswählt. Nützlich, wenn Sie über mehrere Wissensdatenbanken oder Tools verfügen und sicherstellen möchten, dass eine verwendet wird.
- **Tool:** Erzwingt, dass ein bestimmtes benanntes Tool zu Beginn der Antwort genau einmal aufgerufen wird. Wenn Sie beispielsweise ein Knowledge-Base-Tool angeben, fragt das Modell es ab, bevor es antwortet, unabhängig davon, ob es das Tool für erforderlich hält.

Beispiele für die Werkzeugauswahl

Auto (Standard)

```

"toolChoice": {
  "auto": {}
}

```


Beliebig:

```
"toolChoice": {  
  "any": {}  
}
```

Spezifisches Tool:

```
"toolChoice": {  
  "tool": {  
    "name": "get_weather"  
  }  
}
```

Empfangen und Verarbeiten von Nutzungsereignissen des Tools

Wenn Amazon Nova 2 Sonic feststellt, dass ein Tool benötigt wird, sendet es ein `toolUse` Ereignis, das Folgendes enthält:

1. `toolUseID`: eindeutiger Bezeichner für diesen Tool-Aufruf
2. `ToolName`: der Name des auszuführenden Tools
3. `Inhalt`: JSON-Zeichenfolge mit Parametern, die aus der Anfrage des Benutzers extrahiert wurden
4. `SessionID`: Aktuelle Sitzungs-ID
5. `Rolle`: für Ereignisse zur Verwendung von Tools auf „TOOL“ gesetzt

Beispiel für ein Ereignis zur Verwendung eines Tools

```
{  
  "event": {  
    "toolUse": {  
      "completionId": "<completion-id>",  
      "content": "{\"location\": \"Seattle\", \"units\": \"fahrenheit\"}",  
      "contentId": "<content-id>",  
      "promptName": "<prompt-id>",  
      "role": "TOOL",  
      "sessionId": "<session-id>",  
      "toolName": "get_weather",  
      "toolUseId": "<tool-use-id>"  
    }  
  }  
}
```

```
}  
}
```

Schritte der Verarbeitung

1. Erhalte das ToolUse-Event von Nova 2 Sonic
2. Extrahieren Sie den Namen und die Parameter des Tools aus dem Ereignis
3. Führen Sie Ihre Toollogik aus (API-Aufruf, Datenbankabfrage usw.)
4. Geben Sie das Ergebnis mithilfe eines ToolResult-Ereignisses zurück

Beispiel für ein Ereignis ToolResult

```
{  
  "event": {  
    "toolResult": {  
      "promptName": "<prompt-id>",  
      "contentName": "<content-id>",  
      "content": "{\\"temperature\\": 72, \\"condition\\": \\"sunny\\", \\"humidity\\":  
45}"  
    }  
  }  
}
```

Best Practices

- Klare Beschreibungen: Schreiben Sie detaillierte Werkzeugbeschreibungen, damit Nova 2 Sonic versteht, wann die einzelnen Tools verwendet werden müssen.
- Parameter validieren: Überprüfen Sie die Werkzeugparameter immer vor der Ausführung, um Fehler zu vermeiden. Definieren Sie Werkzeugparameter, wann immer möglich, mithilfe eines geeigneten JSON-Schemas mit strukturierten Datentypen (wie Aufzählungen, Zahlen oder Booleschen Werten) anstelle von Zeichenketten mit offenen Enden.
- Fehlerbehandlung: Gibt aussagekräftige Fehlermeldungen in ToolResult-Ereignissen zurück, wenn Tools fehlschlagen.
- Asynchrone Ausführung: Nutzen Sie asynchrone Tool-Aufrufe, um den Konversationsfluss aufrechtzuerhalten.
- Benennung von Tools: Verwenden Sie beschreibende, aktionsorientierte Namen (wie `get_weather`, `search_database`, `send_email`).

Asynchroner Werkzeugaufruf


Im Gegensatz zu herkömmlichen synchronen Toolaufrufen, bei denen die KI unbemerkt auf Werkzeugergebnisse wartet, ermöglicht der asynchrone Ansatz von Amazon Nova 2 Sonic Folgendes:

- Akzeptieren Sie weiterhin Benutzereingaben, während die Tools ausgeführt werden
- Beantworten Sie neue Fragen, ohne auf ausstehende Tool-Ergebnisse zu warten
- Bearbeiten Sie mehrere Tool-Aufrufe gleichzeitig
- Sorgen Sie für einen natürlichen Gesprächsfluss ohne unangenehme Pausen
- Es ist keine zusätzliche Konfiguration erforderlich. Das asynchrone Aufrufen von Tools funktioniert sofort.

Funktionsweise

Wenn Nova 2 Sonic einen Toolaufruf ausgibt, wird die Konversation nicht unterbrochen. Stattdessen hört es weiter zu und reagiert auf natürliche Weise, bis das Tool eintrifft.


Asynchronous Tool Calling Flow



Umgang mit Benutzerunterbrechungen

Wenn ein Benutzer seine Anfrage ändert, während ein Tool ausgeführt wird, verarbeitet Nova 2 Sonic diese auf intelligente Weise, ohne ausstehende Tool-Aufrufe abubrechen.

Async Tool Calling with User Interruption



Beispielszenario

```

User: "Can I book a flight from Boston to Chicago?"
Agent: "Sure, let me look that up for you."
Agent: [initiates tool call for Chicago flights]
User: "Actually, I want to go to Seattle"
Agent: "Ok let me update that search"
Agent: [initiates tool call for Seattle flights]
[First tool returns with Chicago flight results]
Agent: [receives Chicago results and processes them contextually]
  
```

Funktionsweise

Werkzeugergebnisse werden immer geliefert: Wenn ein Werkzeugabruf abgeschlossen ist, wird das Ergebnis immer an das Modell gesendet, auch wenn der Benutzer seine Anforderung geändert

hat. Das Modell bestimmt anhand seiner Argumentationsfähigkeiten, wie mit den Informationen umgegangen werden soll.

Context-aware Verarbeitung: Das Modell versteht den Konversationskontext und kann mit veralteten Toolergebnissen angemessen umgehen. Beispiel:

- Wenn der Benutzer „Danke“ sagt, nachdem er seine Meinung geändert hat, benötigt das Modell immer noch die ursprünglichen Ergebnisse für den Kontext
- Wenn der Benutzer seine Anfrage ändert, kann das Modell die ursprünglichen Ergebnisse bestätigen und sich gleichzeitig auf die neue Anfrage konzentrieren

Keine automatische Stornierung: Das System storniert oder ignoriert Tool-Aufrufe, die auf neuen Benutzereingaben basieren, nicht automatisch. Dadurch wird sichergestellt, dass das Modell über vollständige Informationen verfügt, um intelligente Entscheidungen darüber zu treffen, wie es reagieren soll.

Integrationen

Amazon Nova 2 Sonic kann in verschiedene Frameworks und Plattformen integriert werden, um Konversations-KI-Anwendungen zu erstellen. Diese Integrationen bieten vorgefertigte Komponenten und vereinfachte APIs für gängige Anwendungsfälle.

Strands, Agenten

Strands Agents ist ein einfaches, aber leistungsstarkes SDK, das einen modellgetriebenen Ansatz für die Erstellung und Ausführung von KI-Agenten verfolgt. Von einfachen Konversationsassistenten bis hin zu komplexen autonomen Workflows, von der lokalen Entwicklung bis zur Produktionsbereitstellung — Strands Agents passt sich Ihren Bedürfnissen an.

Eine umfassende Dokumentation zum Strands-Framework finden Sie in der [offiziellen Strands-Dokumentation](#).

The Strands BidiAgent bietet Audio- und Textinteraktionen in Echtzeit über persistente Streaming-Verbindungen. Im Gegensatz zu herkömmlichen Anfrage-Antwort-Mustern führt dieser Agent lang andauernde Konversationen und unterstützt Unterbrechungen, gleichzeitige Verarbeitung und kontinuierliche Audioantworten.

Voraussetzungen:

- Python 3.8 oder höher installiert
- Anmeldeinformationen für AWS konfigurierte Benutzer mit Zugriff auf Amazon Bedrock
- Grundkenntnisse der Python-Syntax `async/await`

Code-Beispiel:

Codebeispiel

Installation (Installation):

Installieren Sie die erforderlichen Pakete:

```
pip install strands-agents strands-agents-tools
```

Führen Sie dieses Beispiel aus:

```
import asyncio
from strands.experimental.bidi.agent import BidiAgent
from strands.experimental.bidi.io.audio import BidiAudioIO
from strands.experimental.bidi.io.text import BidiTextIO
from strands.experimental.bidi.models.novasonic import BidiNovaSonicModel
from strands_tools import calculator

async def main():
    """Test the BidirectionalAgent API."""
    # Audio and Text input/output utility
    audio_io = BidiAudioIO(audio_config={})
    text_io = BidiTextIO()

    # Nova Sonic model
    model = BidiNovaSonicModel(region="us-east-1")

    async with BidiAgent(model=model, tools=[calculator]) as agent:
        print("New BidiAgent Experience")
        print("Try asking: 'What is 25 times 8?' or 'Calculate the square root of 144'")

        await agent.run(
            inputs=[audio_io.input()],
            outputs=[audio_io.output(), text_io.output()]
        )
```

```
if __name__ == "__main__":
    try:
        asyncio.run(main())
    except KeyboardInterrupt:
        print("\nConversation ended by user")
    except Exception as e:
        print(f"Error: {e}")
        import traceback
        traceback.print_exc()
```

1. Import: Erforderliche Modelle

```
from strands.experimental.bidi.agent import BidiAgent
from strands.experimental.bidi.io.audio import BidiAudioIO
from strands.experimental.bidi.io.text import BidiTextIO
from strands.experimental.bidi.models.novasonic import BidiNovaSonicModel
from strands_tools import calculator
```

- **BidiAgent:** Die wichtigste Agentenklasse, die bidirektionale Konversationen orchestriert
- **BidiAudioIO:** Verwaltet die Audioeingabe und -ausgabe für Sprachinteraktionen
- **BidiTextIO:** Bietet Textausgabe für Transkriptionen und Antworten
- **BidiNovaSonicModel** Der Modell-Wrapper Nova 2 Sonic
- **Taschenrechner:** Ein vorgefertigtes Tool für mathematische Operationen

2. Audio und Text konfigurieren I/O

```
audio_io = BidiAudioIO(audio_config={})
text_io = BidiTextIO()
```

Das BidiAudio IO verwaltet den Mikrofoneingang und den Lautsprecherausgang, während BidiText IO Texttranskriptionen und -antworten in der Konsole anzeigt.

3. Initialisieren Sie das Modell

```
model = BidiNovaSonicModel(region="us-east-1")
```

Erstellen Sie eine Nova Sonic-Modellinstanz. Der Parameter Region gibt die AWS Region an, in der das Modell bereitgestellt wird.

4. Erstellen Sie den Agenten und führen Sie ihn aus

```
async with BidiAgent(model=model, tools=[calculator]) as agent:
    await agent.run(
        inputs=[audio_io.input()],
        outputs=[audio_io.output(), text_io.output()]
    )
```

Der Agent wird erstellt mit:

- Modell: Das zu verwendende Nova 2 Sonic-Modell
- Tools: Liste der Tools, die der Agent aufrufen kann (z. B. Taschenrechner)
- Eingänge: Audioeingang vom Mikrofon
- Ausgänge: Audioausgabe an Lautsprecher und Textausgabe an die Konsole


Framework-Integrationen

Amazon Nova 2 Sonic kann in verschiedene Frameworks und Plattformen integriert werden, um anspruchsvolle Sprachanwendungen zu erstellen. Die folgenden Beispiele veranschaulichen Integrationsmuster mit gängigen Frameworks.

Amazon Grundgestein AgentCore

Amazon Bedrock AgentCore bietet eine verwaltete Laufzeitumgebung für die Bereitstellung von Nova 2 Sonic-Anwendungen mit Sicherheit und Skalierbarkeit auf Unternehmensniveau. AgentCore vereinfacht die Bereitstellung von KI-Sprachanwendungen in Echtzeit, indem es sich um Infrastruktur, Authentifizierung und Konnektivität kümmert. WebSocket

AgentCore Architecture



Die wichtigsten Funktionen:

- **Bidirektionales Streaming** — Native Unterstützung für die Vollduplex-Streaming-Schnittstelle von Nova Sonic mit Echtzeit-Eventverarbeitung und Kommunikation mit geringer Latenz.
- **WebSocket Infrastruktur** — Production-ready WebSocket Server mit automatischer Skalierung, Verbindungsmanagement und Fehlerbehebung.
- **Container-Bereitstellung** — Stellen Sie Nova Sonic-Anwendungen als Container in einer verwalteten Infrastruktur mit horizontaler Skalierung und unabhängiger Versionierung bereit.
- **Unternehmenssicherheit** — Fine-grained Authentifizierung über IAM und SigV4, VPC-Isolierung und umfassende Auditprotokollierung.

Die Architektur zeigt, wie Client-Anwendungen über WebSocket SigV4-Authentifizierung eine Verbindung zu AgentCore Runtime herstellen. Die containerisierte Umgebung umfasst Ihren WebSocket Server, Ihre Anwendungslogik und den Nova Sonic Client, die alle über die bidirektionale Streaming-API mit Nova Sonic kommunizieren.

Vorteile:

- Vereinfachter Betrieb: Konzentrieren Sie sich auf die Anwendungslogik und AgentCore verwalten Sie gleichzeitig Infrastruktur, Skalierung und Zuverlässigkeit.
- Unternehmenssicherheit: Built-in Authentifizierungs-, Autorisierungs- und Compliance-Funktionen für Produktionsbereitstellungen.
- Kosteneffizient: Dank automatischer Skalierung und Ressourcenoptimierung zahlen Sie nur für das, was Sie tatsächlich nutzen.
- Produktivität der Entwickler: Verkürzen Sie die Zeit bis zur Produktion mit verwalteter WebSocket Infrastruktur und Container-Bereitstellung.

Anwendungsfälle


- Sprachassistenten für den Kundenservice mit sicherer Authentifizierung
- Sprachanwendungen für Unternehmen, die eine IAM-Integration erfordern
- Multi-tenant Sprachplattformen mit isolierten Bereitstellungen
- Voice-enabled Anwendungen, für die Konformität und Prüfprotokolle erforderlich sind

Eine ausführliche Dokumentation zur Bereitstellung von Nova Sonic mit AgentCore finden Sie in der [Amazon AgentCore Bedrock-Dokumentation](#).

LiveKit

LiveKit ist eine Open-Source-Plattform für die Erstellung von Audio- und Videoanwendungen in Echtzeit. Die Integration mit Amazon Nova 2 Sonic ermöglicht es Entwicklern, dialogorientierte Sprachschnittstellen zu erstellen, ohne komplexe Audiopipelines oder Signalprotokolle verwalten zu müssen.

Ausführliche Implementierungsbeispiele und Codebeispiele finden Sie in der [LiveKit AWS Integrationsdokumentation](#).



So funktioniert es:

- **Client-Ebene:** Web-, Mobil- oder Desktop-Anwendungen stellen eine Verbindung über LiveKit die Client-SDKs her, die die Audioaufnahme, das WebRTC-Streaming und die Wiedergabe übernehmen.
- **LiveKit Server:** Dient als Echtzeit-Kommunikationszentrum, verwaltet WebRTC-Verbindungen, leitet Audiostreams weiter und verarbeitet den Sitzungsstatus mit Optimierung bei niedriger Latenz.
- **LiveKit Agent:** Python-based Agent, der Audio vom Server empfängt, es über das Nova Sonic-Plugin verarbeitet und Antworten zurückstreamt. Beinhaltet integrierte Funktionen wie Sprachaktivitätserkennung und Abbiegeverwaltung.
- **Amazon Nova 2 Sonic:** Verarbeitet den Audiostream über eine bidirektionale Streaming-API, führt Spracherkennung durch, versteht natürliche Sprache und generiert Konversationsantworten mit synthetisierter Sprache.


Pipecat

Pipecat ist ein Framework für die Entwicklung von Sprach- und multimodalen Konversations-KI-Anwendungen. Es bietet eine modulare, Pipeline-basierte Architektur, die mehrere Komponenten orchestriert, um intelligente Sprachanwendungen mit Amazon Nova Sonic und anderen Diensten zu erstellen. AWS

[Ausführliche Implementierungsbeispiele und Codebeispiele finden Sie in der PipeCat AWS Integrationsdokumentation.](#)

Die wichtigsten Funktionen:

- Pipeline-Architektur: Modulares Python-based Framework für die Zusammenstellung von KI-Sprachkomponenten wie ASR, NLU, TTS und mehr.
- Pipecat-Flows: State-Management-Framework für den Aufbau komplexer Konversationslogik und die Ausführung von Tools.
- WebRTC-Unterstützung: Built-in Integration mit Daily und anderen WebRTC-Anbietern für Audio-Streaming in Echtzeit.
- AWS Integration: Native Unterstützung für Amazon Bedrock, Amazon Transcribe und Amazon Polly.



Die Architektur umfasst:

- WebRTC-Transport: Real-time Audio-Streaming zwischen Client-Geräten und Anwendungsserver.
- Sprachaktivitätserkennung (VAD): Silero VAD mit konfigurierbarer Spracherkennung und Geräuschunterdrückung.
- Spracherkennung: Amazon Transcribe für eine genaue Sprache-zu-Text-Konvertierung in Echtzeit.
- Natürliches Sprachverständnis: Amazon Nova Pro auf Bedrock mit latenzoptimierter Inferenz.
- Ausführung des Tools: Pipecat Flows für API-Integration und Backend-Serviceanfragen.
- Generierung von Antworten: Amazon Nova Pro für kohärente, kontextsensitive Antworten.
- Text-to-speech: Amazon Polly mit generativen Stimmen für eine naturgetreue Sprachausgabe.


Bereitstellen auf AWS

Stellen Sie Ihre Nova Sonic-Anwendungen AWS mithilfe von Infrastructure as Code mit AWS CDK (Cloud Development Kit) bereit. Dieser Ansatz ermöglicht wiederholbare, versionskontrollierte Bereitstellungen mit integrierten Best Practices.

Optionen für die Bereitstellung

- Amazon ECS (Elastic Container Service): Vollständig verwaltete Container-Orchestrierung mit Application Load Balancer Balancer-Integration, auto-scaling und serverloser Fargate-Ausführung.
- Amazon EKS (Elastic Kubernetes Services): Managed Kubernetes für komplexe Orchestrierung, fortschrittliche Netzwerke, Bereitstellungen in mehreren Regionen und ein umfangreiches Tooling-Ökosystem.
- AWS CDK: AWS CDK ermöglicht es Ihnen, die Cloud-Infrastruktur mithilfe vertrauter Programmiersprachen zu definieren.

[Ein vollständiges, produktionsreifes Beispiel für die Bereitstellung von Nova Sonic mit AWS CDK finden Sie im CDK-Beispiel unter. Speech-to-Speech GitHub](#) In diesem Beispiel wird Folgendes gezeigt:



- Komplettes CDK-Infrastruktur-Setup mit TypeScript

- WebSocket Serverimplementierung für Echtzeitkommunikation
- Container-Einsatz mit ECS und Fargate
- Application Load Balancer Balancer-Konfiguration zur Unterstützung WebSocket
- Einrichtung von VPC-Netzwerken und Sicherheitsgruppen
- CloudWatch Überwachung und Protokollierung
- Bewährte Methoden für Produktionsbereitstellungen


Multi-agentic Systeme

Multi-agent Architektur ist ein weit verbreitetes Muster für die Entwicklung von KI-Assistenten, die komplexe Aufgaben bewältigen. In einem Sprachassistenten, der von Nova 2 Sonic unterstützt wird, koordiniert diese Architektur mehrere spezialisierte Agenten, wobei jeder Agent unabhängig arbeitet, um Parallelverarbeitung, modulares Design und skalierbare Lösungen zu ermöglichen.

Nova Sonic dient als Orchestrator in einem System mit mehreren Agenten und erfüllt zwei Hauptfunktionen:

Verwaltung des Gesprächsflusses: Stellt sicher, dass alle erforderlichen Informationen gesammelt werden, bevor mit dem nächsten Gesprächsschritt fortgefahren wird.

Klassifizierung der Absichten: Analysiert Benutzeranfragen und leitet sie an den entsprechenden spezialisierten Unteragenten weiter.



Das obige Diagramm zeigt einen Sprachassistenten für Bankgeschäfte, der eine Multi-Agenten-Architektur verwendet. Der Konversationsablauf beginnt mit einer Begrüßung und der Erfassung des Benutzernamens. Anschließend werden Anfragen im Zusammenhang mit Bankgeschäften oder Hypotheken über spezialisierte Unteragenten bearbeitet.

Beispiel für einen Gesprächsablauf:

1. Der Benutzer stellt eine Verbindung zum Sprachassistenten her.
2. Nova 2 Sonic: „Hallo! Wie ist dein Name?“
3. Benutzer: „Ich heiße John“
4. Nova 2 Sonic: „Hallo John, wie kann ich dir heute helfen?“
5. Benutzer: „Ich möchte meinen Kontostand überprüfen“
6. Nova 2 Sonic: [Routen zum Authentifizierungsagenten]
7. Authentifizierungsagent: „Bitte geben Sie Ihre Konto-ID an“
8. Benutzer: „12345“

9. Authentifizierungsagent: [Überprüft die Identität]
- 10.Nova 2 Sonic: [Routen zum Bankagenten]
- 11.Bankagent: „Ihr aktuelles Guthaben beträgt 5.431.10\$“

Dieses Beispiel zeigt zwar, dass Subagenten das auf Amazon Bedrock bereitgestellte Strands Agents-Framework verwenden AgentCore, aber die Architektur ist flexibel. Sie können wählen:

- Ihr bevorzugtes Agenten-Framework
- Jeder LLM-Anbieter
- Benutzerdefinierte Hosting-Optionen
- Verschiedene Orchestrierungsmuster

Vorteile:

- Modularität: Jeder Agent konzentriert sich auf eine bestimmte Domäne, wodurch das System einfacher zu warten und zu aktualisieren ist.
- Skalierbarkeit: Fügen Sie neue Agenten hinzu, ohne bestehende zu ändern, sodass Ihr System mit Ihren Anforderungen mitwachsen kann.
- Parallele Verarbeitung: Es können mehrere Agenten gleichzeitig arbeiten, was die Antwortzeiten bei komplexen Anfragen verbessert.
- Spezialisierung: Jeder Agent kann mithilfe der am besten geeigneten Tools und Wissensdatenbanken für seine spezifische Aufgabe optimiert werden.
- Fehlerisolierung: Wenn ein Agent ausfällt, funktionieren die anderen weiter, wodurch die allgemeine Systemzuverlässigkeit verbessert wird.

Weitere Informationen und Codebeispiele finden Sie in [diesem Blog](#).

Praktische Beispiele finden Sie im [Nova Sonic Workshop Multi-Agent Lab](#).

Integration der Telefonie

Amazon Nova 2 Sonic lässt sich mit Telefonanbietern integrieren, um AI-powered Sprachanwendungen zu ermöglichen, auf die über Telefonanrufe zugegriffen werden kann. Dieser Leitfaden behandelt die Integration mit Twilio, Vonage und anderen SIP-based Systemen zum Aufbau von Contact-Center-Lösungen und Sprachagenten.

Twilio: Cloud-Kommunikationsplattform mit programmierbaren Sprach- und Medienstreaming-Funktionen.

Vonage: Globale Kommunikations-APIs mit Sprach WebSocket -, Audiostreaming- und SIP-Konnektivität.

AWS bietet eine umfassende Beispielimplementierung, die Nova Sonic in einer Contact-Center-Umgebung mit Echtzeitanalysen und Telefonie-Integration demonstriert.

Repository: [Beispiel für ein Sonic Contact Center mit Telefonie](#)

Fortschrittliche Systeme mit Amazon Nova

-Übersicht

Dieser Abschnitt bietet umfassende Anleitungen für Poweruser, die fortgeschrittene Muster mit Nova-Modellen implementieren. Diese Funktionen ermöglichen anspruchsvolle Anwendungen wie Toolintegration, Retrieval-Augmented Generation (RAG) und autonome KI-Agenten.

Erweitertes Denken in Amazon Nova 2

Amazon Nova 2 Lite bietet erweiterte Denkfunktionen, die es dem Modell ermöglichen, bei komplexen Problemen tiefer zu denken. Diese optionale Funktion gibt Ihnen die Kontrolle darüber, wann und wie das Modell zusätzliche Rechenressourcen zuweist, um schwierige Aufgaben zu bewältigen.

So funktioniert erweitertes Denken

Amazon Nova 2 führt erweitertes Denken als Hybridfunktion ein. Sie haben die vollständige Kontrolle:

- **Erweitertes Denken AUS (Standard):** Amazon Nova 2 arbeitet mit effizientem latentem Denken, das sich optimal für alltägliche Aufgaben und umfangreiche Anwendungen eignet.
- **Erweitertes Denken AKTIVIERT:** Amazon Nova 2 bietet explizite step-by-step Argumentation, die sich am besten für komplexe Probleme eignet, die eine gründliche Analyse erfordern.

Bemühen um Argumentation

Im Folgenden werden verschiedene Ebenen des Argumentationsaufwands dargestellt.

Geringer Aufwand (maxReasoningEffort: „gering“)

Ideal für: Aufgaben mit erhöhter Komplexität, die strukturiertes Denken erfordern. Sie können dies beispielsweise für Codeüberprüfungen und Verbesserungsvorschläge verwenden, bei denen das Modell die vorhandene Codequalität sorgfältig berücksichtigen muss, für Analyseaufgaben, die eine sorgfältige Berücksichtigung mehrerer Faktoren erfordern, oder für Problemlösungsszenarien, die von einem methodischen Ansatz profitieren. Ein geringer Aufwand ist ideal für komplexe Aufgaben, bei denen grundlegende Überlegungen die Genauigkeit verbessern, ohne dass eine gründliche Planung in mehreren Schritten erforderlich ist.

Mittlerer Aufwand (maxReasoningEffort: „mittel“)

Am besten geeignet für: Mehrstufige Aufgaben und Codierungsworkflows. Sie können dies beispielsweise für Softwareentwicklung und Debugging verwenden, bei denen das Modell die bestehende Codestruktur verstehen muss, bevor Änderungen implementiert werden, für die Codegenerierung, die die Koordination mehrerer Dateien oder Komponenten erfordert, für mehrstufige Berechnungen mit gegenseitigen Abhängigkeiten oder für Planungsaufgaben mit mehreren Einschränkungen. Ein mittlerer Aufwand ist optimal für agentische Workflows, die mehrere Tools koordinieren und erfordern, dass das Modell den Kontext mehrerer sequentieller Operationen beibehält.

Hoher Aufwand (maxReasoningEffort: „hoch“)

Am besten geeignet für: STEM-Argumentation und fortgeschrittene Problemlösung. Sie können dies beispielsweise für fortgeschrittene mathematische Probleme und Beweise verwenden, die eine strenge step-by-step Überprüfung erfordern, für wissenschaftliche Analysen und Forschungsaufgaben, die gründliche Untersuchungen erfordern, für ein komplexes Systemdesign mit architektonischen Überlegungen über mehrere Dimensionen oder für kritische Entscheidungsszenarien mit erheblichen Auswirkungen. Ein hoher Aufwand sorgt für maximale Genauigkeit bei Aufgaben, die eine ausgeklügelte Argumentation, eine sorgfältige Bewertung von Alternativen und eine gründliche Validierung der Schlussfolgerungen erfordern.

Schnellstart: Erweitertes Denken ermöglichen

Erweitertes Denken wird durch den `reasoningConfig` Parameter gesteuert.

```
import boto3

bedrock = boto3.client('bedrock-runtime', region_name='us-east-1')

response = bedrock.converse(
    modelId='us.amazon.nova-2-lite-v1:0',
    system=[{"text": "You are a highly capable personal assistant"}],
    messages=[{
        "role": "user",
        "content": [{"text": "Provide a meal plan for a gluten free family of 4."}]
    }],
    inferenceConfig={
        "temperature": 0.7,
        "topP": 0.9,
        "maxTokens": 10000
    })
```

```

    },
    additionalModelRequestFields={
        "reasoningConfig": {
            "type": "enabled",
            "maxReasoningEffort": "low"
        }
    }
)

content_list = response["output"]["message"]["content"]

for item in content_list:
    if "reasoningContent" in item:
        reasoning_text = item["reasoningContent"]["reasoningText"]["text"]
        print("=== REASONING ===")
        print(reasoning_text)
        print()
    elif "text" in item:
        print("=== ANSWER ===")
        print(item["text"])

```

Argumentationsparameter:

- type: enabled oder disabled (Standard: disabled)
- maxReasoningEffort: low, medium, oder high

Note

Temperature, TopP und TopK können nicht zusammen mit der maxReasoningEffort Einstellung auf verwendet werden. high Wenn diese Parameter zusammen verwendet werden, tritt ein Fehler auf.

Vollständige Beispiele für Code, der erweitertes Denken nutzt, finden Sie unter [the section called “Code-Bibliothek”](#).

Struktur der Antwort

Wenn Sie „Erweitertes Denken“ aktivieren, bestehen die Antworten aus reasoningContent Blöcken, gefolgt von text Inhaltsblöcken:

```
{
  "output": {
    "message": {
      "role": "assistant",
      "content": [
        {
          "reasoningContent": {
            "reasoningText": {
              "text": "[REDACTED]"
            }
          }
        },
        {
          "text": "Based on the premises, we can conclude..."
        }
      ]
    }
  },
  "stopReason": "end_turn"
}
```

Note

Bei Amazon Nova 2 werden Argumentationsinhalte als [REDACTED] angezeigt. Für Argumentations-Tokens fallen weiterhin Gebühren an, da sie zu einer verbesserten Ausgabequalität beitragen. Wir nehmen dieses Feld jetzt in die Antwortstruktur auf, um die Möglichkeit zu wahren, in future Argumentationsinhalte offenzulegen. Wir arbeiten aktiv mit unseren Kunden zusammen, um herauszufinden, wie der Argumentationsprozess des Modells am besten dargestellt werden kann. Der Inhalt der Argumentation wird als angezeigt. [REDACTED] Für Argumentations-Tokens fallen weiterhin Gebühren an, da diese zur Verbesserung der Antwortqualität beitragen.

Konfigurationsoptionen

Amazon Nova 2 führt einen neuen `reasoningConfig` Parameter ein, den Sie zu Ihrer bestehenden Konversationsanforderungsstruktur hinzufügen können, um Argumentation zu ermöglichen:

```
additionalModelRequestFields={
  "reasoningConfig": {
    "type": "enabled", # or "disabled" (default)
    "maxReasoningEffort": "high" # "low", "medium", or "high"
  }
}
```

Parameter:

- Typ: Zwischen "enabled" und umschalten "disabled" (Standard ist "disabled")
- **maxReasoningEffort**: Wenn diese Option aktiviert ist, können Sie die Tiefe des Denkens steuern
- „niedrig“: Mäßig komplexe Aufgaben
- „mittel“: Komplexe Probleme, die eine eingehende Analyse erfordern
- „hoch“: Gründlichste Argumentation für hochkomplexe Aufgaben

Note

Bei der Verwendung "high" müssen temp, toPP und maxToken nicht gesetzt sein. In diesem Modus führt das Modell eine tiefere Analyse durch, um die beste Lösung zu finden. Diese gründlichere Verarbeitung kann zu einer Ausgabe von mehr als 65.000 Token führen. Die genaue Menge hängt von der Komplexität Ihrer Anfrage ab. Bei einigen Problemen haben wir jedoch festgestellt, dass es bis zu 128.000 Token sind. Dadurch wird sichergestellt, dass Sie eine vollständige und qualitativ hochwertige Argumentation erhalten und keine verkürzten Ergebnisse erhalten.

Unterstützte Modelle

Extended Thinking ist derzeit verfügbar in: Amazon Nova 2 Lite (us.amazon.nova-2-lite-v 1:0)

Erweitertes Denken mit der Verwendung des Tools

Extended Thinking funktioniert problemlos mit dem Aufrufen von Tools, sodass Amazon Nova überlegen kann, welche Tools verwendet werden sollen und wie ihre Ergebnisse zu interpretieren sind.

Grundlegendes zu Argumentation, Tokens und Preisgestaltung

Token-Typen

Token für erweitertes Denken werden als Output-Token abgerechnet:

- Eingabe-Token: Ihr ursprünglicher Anforderungsinhalt (Standardpreis für Eingaben)
- Ausgabetokens: Dazu gehören Begründungstoken und der endgültige sichtbare Inhalt der Antwort (Standardpreise für die Ausgabe)

Aufschlüsselung der Nutzung

Alle drei Tokentypen sind in Ihren Nutzungsmetriken und in der Abrechnung enthalten.

Argumentations-Tokens haben denselben Preis wie Ausgabetokens und werden in der Modellantwort als „REDACTED“ angezeigt.

```
{
  "usage": {
    "inputTokens": 45,
    "outputTokens": 1240,
    "totalTokens": 1285
  }
}
```

Häufig gestellte Fragen

Warum zeigt Amazon Nova 2 Lite „[REDACTED]“ als Argumentationsinhalt an, anstatt den Denkprozess des Modells darzustellen?

Unser Hauptaugenmerk bei dieser Markteinführung liegt darauf, sicherzustellen, dass Nova 2 erstklassige Informationen für Ihre Aufgaben bietet, und Sie werden sehen, dass sich dies in der verbesserten Genauigkeit widerspiegelt.

Wir sind uns bewusst, dass Einblicke in den Argumentationsprozess wertvoll sind, und wir haben ein starkes Kundeninteresse daran gehört, zu verstehen, wie das Modell Probleme durchdenkt.

Wir suchen nach Möglichkeiten, dies bald verfügbar zu machen.

Ihnen werden weiterhin Argumentationsnachweise in Rechnung gestellt, da es sich dabei um tatsächliche Arbeit handelt, die Ihre Output-Qualität verbessert

die `outputTokens` zusammen mit den Antwort-Token erfasst werden.

Woher weiß ich, ob erweitertes Denken funktioniert, wenn das Denken redigiert ist?

Sie können überprüfen, ob erweitertes Denken funktioniert, indem Sie in der Ausgabe nach `reasoningContent` Blöcken in der Antwort suchen (diese erscheinen nur, wenn Argumentation aktiviert ist)

Tools verwenden (Funktionsaufruf)

Tools erweitern die Funktionen von Amazon Nova, indem sie das Modell mit externen Funktionen wie APIs Datenbanken und Codeausführungsumgebungen verbinden. Die Verwendung von Tools ermöglicht Amazon Nova den Zugriff auf Echtzeitinformationen, die Durchführung von Berechnungen und die Interaktion mit externen Systemen.

Grundlegendes zum Arbeitsablauf bei der Verwendung von Tools

Die Verwendung von Tools mit Amazon Nova umfasst drei Hauptphasen:

Benutzerabfrage und Tooldefinition

Definieren Sie Tools, indem Sie JSON-Schemas bereitstellen, die die Funktionen und Eingabeanforderungen der einzelnen Tools beschreiben. Die Werkzeugkonfiguration muss explizite Angaben darüber enthalten, wann und wie die einzelnen Tools verwendet werden.

Auswahl des Werkzeugs

Wenn ein Benutzer eine Nachricht sendet, analysiert Amazon Nova sie, um festzustellen, ob ein Tool erforderlich ist. Diese automatische Toolauswahl untersucht den Kontext und entscheidet, welches Tool (falls vorhanden) aufgerufen werden soll. Wenn Amazon Nova ein geeignetes Tool identifiziert, gibt es den Namen des Tools und die erforderlichen Parameter zurück.

Sie sind dafür verantwortlich, das Tool auf der Grundlage der Anfrage des Modells auszuführen. Das bedeutet, Code zu schreiben, der die Funktionalität des Tools aufruft und die vom Modell bereitgestellten Eingabeparameter verarbeitet.

Ergebnisse zurückgeben

Senden Sie nach der Ausführung des Tools die Ergebnisse in einem strukturierten Format mit JSON oder einer Kombination aus Text und Bildern an Amazon Nova zurück. Amazon Nova bezieht die Ausgabe des Tools in die endgültige Antwort ein. Wenn während der Ausführung Fehler auftreten, geben Sie dies in der Antwort des Tools an, damit Amazon Nova entsprechende Anpassungen vornehmen kann.

Erstellen Sie ein Tool

Definieren Sie Werkzeuge mithilfe einer Werkzeugkonfiguration, die eine Reihe von Werkzeugen und optional einen Werkzeugauswahlparameter umfasst. Jede Werkzeugspezifikation muss Folgendes enthalten:

- Name: Klare Kennung für das Tool
- Beschreibung: Prägnante Erläuterung der Funktionen des Tools
- Eingabeschema: JSON-Schema, das die erforderlichen und optionalen Parameter definiert

Example Beispiel für eine Tool-Konfiguration

```
tool_config = {
  "tools": [
    {
      "toolSpec": {
        "name": "calculator",
        "description": "A calculator tool that can execute a math equation",
        "inputSchema": {
          "json": {
            "type": "object",
            "properties": {
              "equation": {
                "type": "string",
                "description": "The full equation to evaluate"
              }
            }
          },
          "required": ["equation"]
        }
      }
    }
  ]
}
```

```
]
}
```

Bewährte Methoden für Werkzeugdefinitionen

- Achten Sie darauf, dass der Name und die Beschreibung die genaue Funktionalität des Tools explizit wiedergeben. Vermeiden Sie Tools, die sich semantisch zu ähnlich sind
- Nehmen Sie wichtige Unterscheidungsmerkmale in die Beschreibung auf, damit das Modell zwischen ähnlichen Tools unterscheiden kann
- Beschränken Sie JSON-Schemas auf zwei Verschachtelungsebenen, um eine optimale Leistung zu erzielen
- Beschränken Sie Eingaben mithilfe von Schematypen (z. B. enum, int, float), anstatt die Struktur im Klartext zu beschreiben
- Geben Sie mithilfe der JSON-Schemanotation erforderliche und optionale Parameter an (z. B. „required“: [„param1“, „param2“])
- Validieren Sie Ihr JSON-Schema vor dem Absenden mit einem Standardvalidator
- Platzieren Sie lange Zeichenkettenargumente an letzter Stelle im Schema und vermeiden Sie es, sie zu verschachteln

Strukturierte Ausgabe mit eingeschränkter Dekodierung

Amazon Nova-Modelle nutzen eingeschränkte Dekodierung, um eine hohe Zuverlässigkeit der generierten Ausgaben zu gewährleisten. Diese Technik verwendet Grammatik, um mögliche Token bei jedem Generierungsschritt einzuschränken, wodurch ungültige Schlüssel vermieden und korrekte Datentypen auf der Grundlage Ihres definierten Schemas durchgesetzt werden.

Example Beispiel für eine strukturierte Ausgabe

```
tool_config = {
  "tools": [
    {
      "toolSpec": {
        "name": "ProductAnalysis",
        "description": "Analyze product information from text.",
        "inputSchema": {
          "json": {
            "type": "object",
            "properties": {
```

```

        "name": {
            "type": "string",
            "description": "Product name"
        },
        "rating": {
            "maximum": 5,
            "description": "Customer rating 1-5",
            "type": ["number", "null"],
            "minimum": 1
        },
        "features": {
            "description": "Key product features",
            "type": "array",
            "items": {"type": "string"}
        },
        "category": {
            "type": "string",
            "description": "Product category"
        },
        "price": {
            "type": "number",
            "description": "Price in USD"
        }
    },
    "required": ["name", "category", "price", "features"]
}

}

}

},
"toolChoice": {
    "tool": {"name": "ProductAnalysis"}
}
}

```

Optionen zur Werkzeugauswahl

Amazon Nova unterstützt drei Parameter für die Werkzeugauswahl:

Tool

Das angegebene Tool wird einmal aufgerufen, ideal für Anwendungsfälle mit strukturierter Ausgabe

Beliebig

Eines der bereitgestellten Tools wird mindestens einmal aufgerufen, was für API-Auswahlszenarien nützlich ist

Automatisch

Das Modell entscheidet, ob und wie viele Tools aufgerufen werden sollen (Standardverhalten)

Rufen Sie ein Tool auf

Wenn Amazon Nova beschließt, ein Tool aufzurufen, gibt es als Teil der Assistentennachricht einen Werkzeugverwendungsblock zurück, wobei stopReason auf „tool_use“ gesetzt ist. Der Werkzeugblock enthält den Namen des Tools und seine Eingaben.

Note

Führen Sie die folgenden Codeabschnitte nacheinander (Werkzeug aufrufen → Werkzeugaufruf verarbeiten → Werkzeugergebnisse zurückgeben) in einer einzigen Python-Sitzung aus. Um die Beispiele erneut auszuführen, starten Sie Ihre Python-Sitzung neu.

Example Ein Tool aufrufen

```
import boto3
import json

# Create Bedrock client
bedrock = boto3.client('bedrock-runtime', region_name='us-east-1')

# Complex calculation that benefits from precise computation
messages = [{
    "role": "user",
    "content": [{
        "text": "Calculate the compound interest on $10,000 invested at 4.75% annual
rate for 7 years, compounded quarterly. Use the formula  $A = P(1 + r/n)^{(nt)}$  where
 $P=10000$ ,  $r=0.0475$ ,  $n=4$ ,  $t=7$ "
    }]
}]

# Define tool configuration with calculator
tool_config = {
```

```

    "tools": [{
        "toolSpec": {
            "name": "calculator",
            "description": "Perform mathematical calculations",
            "inputSchema": {
                "json": {
                    "type": "object",
                    "properties": {
                        "expression": {
                            "type": "string",
                            "description": "Mathematical expression to evaluate"
                        }
                    },
                    "required": ["expression"]
                }
            }
        }
    }]
}

# Invoke Model
response = bedrock.converse(
    modelId="us.amazon.nova-2-lite-v1:0",
    messages=messages,
    toolConfig=tool_config
)

# Extract tool use from response
tool = next(
    block["toolUse"]
    for block in response["output"]["message"]["content"]
    if "toolUse" in block
)

print(f"Tool: {tool['name']}")
print(f"Expression: {tool['input']['expression']}")

```

Tool-Aufrufe werden verarbeitet

Extrahieren Sie den Namen und die Argumente des Tools aus der Nachricht und rufen Sie dann das Tool auf:

```
def calculate(expression):
```

```

    """Evaluate mathematical expression"""
    print(f"Calculating: {expression}")
    P = 10000
    r = 0.0475
    n = 4
    t = 7
    result = P * (1 + r/n) ** (n*t)
    return result

stop_reason = response["stopReason"]

if stop_reason == "tool_use":
    if tool["name"] == "calculator":
        result = calculate(tool["input"]["expression"])

```

Rückgabe von Tool-Ergebnissen

Geben Sie die Werkzeugergebnisse mithilfe des ToolResultBlock Schemas zurück:

```

messages.append(response["output"]["message"])

# Add the tool result
messages.append({
    "role": "user",
    "content": [{
        "toolResult": {
            "toolUseId": tool['toolUseId'],
            "content": [{"json": {"result": result}}],
            "status": "success"
        }
    ]
})

# Send the tool result to the model
response = bedrock.converse(
    modelId="us.amazon.nova-2-lite-v1:0",
    messages=messages,
    toolConfig=tool_config
)

# Extract and display final response
final_text = next(
    block["text"]

```



```
    for block in response["output"]["message"]["content"]
    if "text" in block
)

print(f"\nFinal Response:\n{final_text}")
```

Fehlerbehandlung

Melden Sie Fehler an Amazon Nova zurück, damit die Anfrage geändert werden kann, und versuchen Sie es erneut:

```
tool_result_message = {
    "role": "user",
    "content": [
        {
            "toolResult": {
                "toolUseId": tool["toolUseId"],
                "content": [{"text": "A validation exception occurred on field:
sample.field"}],
                "status": "error"
            }
        }
    ]
}
```

Sicherheitsüberlegungen

- Stellen Sie sicher, dass Tools vorhanden sind, bevor Sie sie aufrufen
- Stellen Sie sicher, dass die Eingaben korrekt formatiert sind
- Stellen Sie vor der Ausführung des Tools sicher, dass die entsprechenden Berechtigungen vorhanden sind
- Verlassen Sie sich auf Sitzungsdetails, anstatt Amazon Nova zu erlauben, Benutzerinformationen in Tool-Aufrufe einzufügen
- Denken Sie daran, dass dies zu Halluzinationen bei Toolaufrufen führen LLMs kann. Überprüfen Sie immer, bevor Sie sie ausführen

Integrierte Systemtools

Die Modelle von Amazon Nova 2.0 enthalten vollständig verwaltete integrierte Tools, für die keine benutzerdefinierte Implementierung erforderlich ist. Aktivieren Sie diese Tools mit einem einfachen Schalter in der Converse-API.

Code-Interpreter

Mit dem Code Interpreter kann Nova Python-Code in isolierten Sandbox-Umgebungen sicher ausführen. Dieses Tool wurde für mathematische Berechnungen, logische Operationen und iterative Algorithmen entwickelt.

Note

Der Code Interpreter ist in den Regionen IAD, PDX und NRT verfügbar. AWS Verwenden Sie Global CRIS, um sicherzustellen, dass Ihre Anfragen an eine unterstützte Region weitergeleitet werden. Wenn Sie Bedrock API-Schlüssel verwenden, müssen Sie den Richtliniendefinitionen manuell InvokeTool Berechtigungen hinzufügen. Die Bedrock-Standardrolle erlaubt die InvokeTool Aktion nicht.

Aktivieren Sie den Code Interpreter, indem Sie den SystemTool-Parameter angeben:

```
import boto3
import json

bedrock = boto3.client('bedrock-runtime', region_name='us-east-1')

tool_config = {
    "tools": [{
        "systemTool": {
            "name": "nova_code_interpreter"
        }
    }]
}

response = bedrock.converse(
    modelId="us.amazon.nova-2-lite-v1:0",
    messages=[{
        "role": "user",
        "content": [{
```

```

        "text": "What is the average of 10, 24, 2, 3, 43, 52, 13, 68, 6, 7, 902,
82"
    ]]
  ]],
  toolConfig=tool_config,
  inferenceConfig={"maxTokens": 10000, "temperature": 0}
)

# Pretty print the response
for block in response["output"]["message"]["content"]:
    if "toolUse" in block:
        print("=== Tool Use ===")
        print(f"Tool: {block['toolUse']['name']}")
        print(f"Code:\n{block['toolUse']['input']['snippet']}\n")

    elif "toolResult" in block:
        print("=== Tool Result ===")
        result = block['toolResult']['content'][0]['json']
        print(f"Output: {result['stdOut']}")
        if result['stdErr']:
            print(f"Error: {result['stdErr']}")
        print(f"Exit Code: {result['exitCode']}\n")

    elif "text" in block:
        print("=== Final Answer ===")
        print(block["text"])

```

Der Interpreter führt Code in einer Sandbox aus und gibt Ergebnisse in einem Standardschema zurück:

```

{
  "stdOut": "String",
  "stdErr": "String",
  "exitCode": "int",
  "isError": "boolean"
}

```

Web Grounding

Web Grounding ermöglicht es Amazon Nova, in Echtzeit auf Informationen aus dem Internet zuzugreifen, up-to-date Antworten zu geben und Halluzinationen zu reduzieren. Aktivieren Sie diese Option, indem Sie das Systemtool `nova_grounding` angeben:

```
tool_config = {  
    "tools": [{  
        "systemTool": {"name": "nova_grounding"}  
    }]  
}
```

Ausführliche Informationen zu Web Grounding finden Sie unter. [the section called “Web Grounding”](#)

Model Context Protocol (MCP)

Das Model Context Protocol (MCP) ist ein offener Standard, der sichere, bidirektionale Verbindungen zwischen Datenquellen und KI-gestützten Tools ermöglicht. Anstatt benutzerdefinierte Adapter für jede API oder jeden Service zu schreiben, führen Sie einen MCP-Server aus und lassen Sie Amazon Nova seine Tools automatisch über eine Client-Bridge erkennen.

Sobald die Verbindung hergestellt ist, behandelt Amazon Nova MCP-Tools wie jede andere externe Integration: Es entscheidet, wann sie aufgerufen werden, sendet die erforderlichen Parameter und bezieht die Ergebnisse in die Antworten ein. Die Verwendung von Amazon Nova mit Strands erleichtert dies mit einer integrierten MCPClient Lösung, die Erkennung, Verbindung und Ergebniszuordnung automatisch verwaltet.

KI-Agenten erstellen

Amazon Nova-Modelle sind für die Erstellung von KI-Agenten mit Amazon Nova Act optimiert. Die Modelle bieten eine verbesserte Nutzung der Tools, eine bessere Argumentation für mehrstufige Aufgaben, eine verbesserte Fähigkeit, den Kontext in komplexen Agenten-Workflows aufrechtzuerhalten, und Unterstützung für Remote-MCP-Tools.

Erstellen eines Agenten

Mit Nova entwickelte KI-Agenten können mehrere Tool-Aufrufe orchestrieren, den Kontext über ausgedehnte Interaktionen hinweg beibehalten und bei Bedarf Kurskorrekturen vornehmen. Erweitertes Denken verändert die Arbeitsabläufe von Agenturen, indem es systematisches Denken im Hinblick auf komplexe Ziele ermöglicht. Erwägen Sie die Verwendung eines Planungsrahmen-SDK wie Strands Agents, um den Planungs- und Ausführungsprozess Ihrer Agentensysteme robuster zu gestalten.

Entwurfsmuster für Agenten

Beim Entwerfen von Agenten mit Nova:

- Ermöglichen Sie optimale Ergebnisse bei komplexen, mehrstufigen Workflows, die Planung und Überprüfung erfordern
- Implementieren Sie die Toolauswahlauto, um eine flexible Werkzeugauswahl bei allen Interaktionen mit Agenten zu ermöglichen
- Entwerfen Sie eine Fehlerbehandlung, die es den Agenten ermöglicht, den Vorgang mit modifizierten Ansätzen wiederherzustellen und es erneut zu versuchen
- Pflegen Sie den Konversationsverlauf, um den Kontext aller Agenteninteraktionen beizubehalten
- Implementieren Sie robuste Mechanismen zur Inhaltsfilterung und Moderation für unkontrollierte Inhalte, die Ihr Agentensystem konsumiert. Amazon bietet beispielsweise Amazon Bedrock Guardrails an, eine Funktion, mit der Schutzmaßnahmen für mehrere Fundamentmodelle, Wissensdatenbanken und Agenten angewendet werden können. Diese Leitplanken können schädliche Inhalte filtern, abgelehnte Themen blockieren und vertrauliche Informationen wie personenbezogene Daten unkenntlich machen.

Beispiel für einen Agenten mit mehreren Tools

```
tool_config = {  
  "tools": [  
    {  
      "toolSpec": {  
        "name": "calculator",  
        "description": "Perform mathematical calculations",  
        "inputSchema": {  
          "json": {  
            "type": "object",  
            "properties": {  
              "expression": {  
                "type": "string",  
                "description": "Mathematical expression to evaluate"  
              }  
            },  
            "required": ["expression"]  
          }  
        },  
      },  
    },  
    {  
      "toolSpec": {  
        "name": "database_query",
```

```

        #"description": "Query financial database for historical data",
        #"inputSchema": {
            #"json": {
                #"type": "object",
                #"properties": {
                    #"query": {
                        #"type": "string",
                        #"description": "SQL query to execute"
                    #}
                #},
                #"required": ["query"]
            #}
        #}
    #}
#]
}

response = client.converse(
    #modelId=" us.amazon.nova-2-lite-v1:0",
    #messages=[{
        #"role": "user",
        #"content": [{
            #"text": "Analyze our Q3 financial performance across all business units,
calculate year-over-year growth rates with statistical significance testing, and
recommend budget allocation strategies for Q4."
        #}]
    #}],
    #toolConfig=tool_config,
    #inferenceConfig={"maxTokens": 10000, "temperature": 1, "topP": 0.9},
    #additionalModelRequestFields={
        #"reasoningConfig": {
            #"type": "enabled",
            #"maxReasoningEffort": "low"
        #}
    #}
)

```

Aufrufen eines Agenten

Der Agentenaufruf umfasst die Verwaltung des Konversationsflusses, die Verarbeitung von Toolaufrufen und die Beibehaltung des Status über mehrere Interaktionen hinweg.

Antworten der Agenten streamen

Streamen Sie Antworten, um in Echtzeit Einblick in die Überlegungen und Aktionen des Agenten zu erhalten:

```
import boto3
response = client.converse_stream(
    #modelId=" us.amazon.nova-2-lite-v1:0",
    #messages=[{
        #"role": "user",
        #"content": [{
            #"text": "Design a scalable microservices architecture for an e-commerce
platform handling 1M+ daily transactions. Consider data consistency, fault tolerance,
performance, security, and cost optimization."
        #}]
    #}],
    #inferenceConfig={"maxTokens": 10000, "temperature": 10},
    #additionalModelRequestFields={
        #"reasoningConfig": {
            #"type": "enabled",
            #"maxReasoningEffort": "low"
        #}
    #}
)

# Process the streaming response
reasoning_complete = False
for event in response["stream"]:
    #if "contentBlockDelta" in event:
        #delta = event["contentBlockDelta"]["delta"]

        #if "reasoningContent" in delta:
            #reasoning_text = delta["reasoningContent"]["reasoningText"]["text"]
            #print(f"{reasoning_text}", end="", flush=True)
        #elif "text" in delta:
            #if not reasoning_complete:
                #print(f"

Final Architecture Design:
")

    #reasoning_complete = True
    #print(f"{delta['text']}", end="", flush=True)
```

Verwaltung des Status der Agenten

Pflegen Sie den Konversationsverlauf und die Tool-Ergebnisse, um den Kontext zu wahren. Das folgende Beispiel zeigt dies für einen einzigen Zug, aber der Entwickler kann anhand der Workflow-Anforderungen festlegen, wie das gesamte Agentensystem orchestriert werden soll. Darüber hinaus verwalten Amazon Web Services Services-Tools wie Strands den Agentenkontext und den Status des Tools im Namen des Entwicklers.

```
messages = []

messages = []

# Initial user query
messages.append({
    #"role": "user",
    #"content": [{"text": user_query}]
})

# Get agent response
response = client.converse(
    #modelId=" us.amazon.nova-2-lite-v1:0",
    #messages=messages,
    #toolConfig=tool_config,
    #inferenceConfig=inf_params
)

# Add assistant response to history
messages.append(response["output"]["message"])

# Process tool calls and add results
if response["stopReason"] == "tool_use":
    #tool = next(
        #block["toolUse"]
        #for block in response["output"]["message"]["content"]
        #if "toolUse" in block
    #)

    ## Execute tool
    #result = execute_tool(tool["name"], tool["input"])

    ## Add tool result to conversation
    #messages.append({
        #"role": "user",
```



```
#"content": [{
  #"toolResult": {
    #"toolUseId": tool["toolUseId"],
    #"content": [{"json": result}],
    #"status": "success"
  }
}]
#})

## Continue conversation
#response = client.converse(
  #modelId=" us.amazon.nova-2-lite-v1:0",
  #messages=messages,
  #toolConfig=tool_config,
  #inferenceConfig=inf_params
#)
```

Bewährte Methoden für Agenten

Weitere Informationen zu Best Practices für Agenten finden Sie unter [the section called “Best Practices”](#).

Anleitungen zur Entwicklung von Conversational AI-Agenten finden Sie unter [Speech-to-Speech](#).

Web Grounding

Web Grounding ermöglicht es Amazon Nova, im Internet nach aktuellen Informationen zu suchen und Antworten mit Zitaten bereitzustellen. Diese Funktion ist nützlich für Abfragen, die up-to-date Informationen erfordern, die über die Trainingsdaten des Modells hinausgehen.

Wie funktioniert Web Grounding

Wenn Web Grounding für einen Prompt aktiviert ist, werden die folgenden Schritte ausgeführt:

1. Konfiguration anfordern: Ihre Anwendung sendet eine Benutzeraufforderung an die Amazon Bedrock API, wobei nova_grounding als aktiviert ist. systemTool
2. Suche und Analyse: Das Modell bestimmt, ob eine Suche erforderlich ist, führt eine oder mehrere Suchen nach relevanten Informationen durch und bewertet, ob zusätzliche Suchen erforderlich sind, um das Verständnis zu erweitern oder sich eingehender mit bestimmten Unterthemen zu befassen.

3. Generierung von Antworten: Amazon Nova synthetisiert automatisch Informationen aus Suchergebnissen, um eine endgültige API-Antwort zu generieren, die auf Echtzeitinformationen basiert, einschließlich Quellenangaben.

Web Grounding verwenden

Vollständige Beispiele für Code, der Web Grounding verwendet, finden Sie im Abschnitt [Codebeispiele](#).

Um Web Grounding in Ihre Ergebnisse einzubeziehen, geben Sie den folgenden `systemTool` Parameter in Ihrem `ToolConfig`-Block an:

```
import boto3
from botocore.config import Config

# Create the Bedrock Runtime client with extended timeout
bedrock = boto3.client(
    "bedrock-runtime",
    region_name="us-east-1",
    config=Config(read_timeout=3600)
)

# Define the tool configuration
tool_config = {
    "tools": [{
        "systemTool": {
            "name": "nova_grounding"
        }
    }]
}

# Send the request
response = bedrock.converse(
    modelId="us.amazon.nova-2-lite-v1:0",
    messages=[{
        "role": "user",
        "content": [{"text": "What are the latest developments in quantum computing?"}]
    }],
    toolConfig=tool_config
)

# Extract text with interleaved citations
```

```
output_with_citations = ""
content_list = response["output"]["message"]["content"]
for content in content_list:
    if "text" in content:
        output_with_citations += content["text"]
    elif "citationsContent" in content:
        citations = content["citationsContent"]["citations"]
        for citation in citations:
            url = citation["location"]["web"]["url"]
            output_with_citations += f" [{url}]"

print(output_with_citations)
```

Regionale Verfügbarkeit

Web Grounding ist derzeit nur in US-Regionen verfügbar und wird nur von US-amerikanischen CRIS-Profilen unterstützt.

Struktur der Antworten

Nachfolgend finden Sie eine Beispielantwort. Die Antwort wurde gekürzt:

```
{
  "output": {
    "message": {
      "content": [
        {
          "text": "Recent quantum computing developments include...",
          "citationsContent": [
            {
              "location": {
                "web": {
                  "url": "https://example.com/quantum-news",
                  "domain": "example.com"
                }
              }
            }
          ]
        }
      ]
    }
  }
}
```

```
}
```

Jedes Zitat beinhaltet:

- `text`: Ein Abschnitt der vom Modell generierten Antwort.
- `citationsContent`: Der primäre Container für die Zitationsdaten, die sich auf ein Textsegment beziehen.
- `citations`: Ein Container `darin``citationsContent`, der den Ort eines Zitats enthält.
- `location`: Ein Container `darin``citations`, der die Quelle eines Zitats enthält.
- `web`: Ein Container `darin``location`, der die Informationen zur Webquelle enthält.
- `url`: Die vollständige Webadresse (URL) der Quelle des Zitats.
- `domain`: Die Stammdomain der Quell-URL.

Sicherheit bei der Erdung

Ihre Daten verlassen niemals die AWS Infrastruktur. Modellgenerierte Abfragen verbleiben innerhalb der AWS Dienste und werden niemals an das breitere Internet gesendet. Unser umfangreicher interner Websuchindex und unsere Wissensdiagramme priorisieren vertrauenswürdige und qualitativ hochwertige Quellen und filtern schädliche Inhalte beim Eindringen. Schließlich schützen wir Ihre Anwendung mit Laufzeitfilterung vor indirekter Promptinjektion und Fehlinformationen (bitte beachten Sie, dass diese Schutzmaßnahme für nicht-englische Sprachen eingeschränkt ist).

Fehlerbehandlung

Fügen Sie dem Namen `nova_grounding` keinen `toolSpec`-Eintrag hinzu. Wenn Sie ein Tool mit diesem Namen hinzufügen, führt das zu einem Fehler.

Im Folgenden finden Sie eine Liste potenzieller Fehler, die auftreten können, wenn Sie Web Grounding verwenden:

- `malformed_tool_use`
- `max_tokens`
- `malformed_model_output`

Für integrierte Tools sind Berechtigungen erforderlich

Um sicherzustellen, dass Ihre Rolle auf Web Grounding auf Amazon Bedrock zugreifen kann, haben Sie zwei Möglichkeiten:

1. **BedrockFullAccess** Aktivieren Sie dies für Ihre IAM-Rolle: Wenn Ihre Rolle dies getan hat **BedrockFullAccess**, hat sie automatisch Zugriff auf Web Grounding.
2. **Spezifische Berechtigungen hinzufügen (falls erforderlich):** Wenn Sie eine detailliertere Zugriffskontrolle benötigen, fügen Sie diese Richtlinie der IAM-Richtlinie Ihrer Rolle hinzu und ersetzen Sie die Konto-ID durch Ihre ID: AWS-Konto

```
{
  "Statement": [
    {
      "Effect": "Allow",
      "Action": ["bedrock:InvokeTool"],
      "Resource": ["arn:aws:bedrock::{111122223333}:system-tool/
amazon.nova_grounding"]
    }
  ]
}
```

Bei Web Grounding ist der `aws:requestedRegion` Bedingungsschlüssel auf „nicht spezifiziert“ gesetzt. Wenn Ihre bestehenden Richtlinien oder Service Control-Richtlinien (SCPs) diese Bedingung erzwingen, können Zugriffsprobleme auftreten. Dieses Problem kann durch eine Aktualisierung der Bedingung behoben werden, sodass eine „nicht spezifizierte“ `requestedRegion` zulässig ist.

Note

Wenn Sie das Web-Grounding-Tool aktivieren, sind Sie für Ihre Nutzung und die Nutzung durch Ihre Endnutzer von Ausgaben verantwortlich, die begründete Informationen enthalten. Anhand von Zitaten oder Links zum Quellenmaterial wissen Sie, dass Ihre Ausgabe fundierte Informationen enthält. Sie müssen diese Zitate und Links in den Ausgabedaten, die Sie Ihren Endnutzern zur Verfügung stellen, beibehalten und anzeigen.

 Note

Web Grounding ist mit zusätzlichen Kosten verbunden. Weitere Informationen finden Sie unter [AWS Bedrock Pricing](#).

Prompter technischer Leitfaden

Prompt Engineering ist die Praxis, Anweisungen zu entwerfen, um effektiv mit großen Sprachmodellen (LLMs) wie Amazon Nova zu kommunizieren. Prompt Engineering ermöglicht es Ihnen, das Modellverhalten zu kontrollieren, die Ausgabequalität zu verbessern und zuverlässige AI-powered Anwendungen zu entwickeln.

Effektives Prompt-Engineering beinhaltet die Erstellung von Eingaben, die Modelle dazu anleiten, die gewünschten Ergebnisse zu erzielen. Eine gut ausgearbeitete Aufforderung bietet klare Anweisungen, relevanten Kontext und korrekt formatierte Eingabedaten.

Was ist Prompt Engineering

Prompt-Engineering bezieht sich auf die Praxis der Optimierung von Texteingaben in ein großes Sprachmodell (LLM), um die Ausgabe zu verbessern und die gewünschten Antworten zu erhalten. Mithilfe von Eingabeaufforderungen (Prompts) kann ein LLM eine Vielzahl von Aufgaben ausführen, darunter Klassifizierung, Beantwortung von Fragen, Codegenerierung, kreatives Schreiben und mehr. Die Qualität der Prompts für ein LLM kann sich auf die Qualität der Antworten des Modells auswirken. Dieser Abschnitt enthält die erforderlichen Informationen, um mit Prompt-Engineering zu beginnen. Es behandelt auch Tools, die Ihnen helfen, das bestmögliche Eingabeaufforderungsformat für Ihren Anwendungsfall zu finden, wenn Sie ein LLM auf Amazon Bedrock verwenden.

Die Wirksamkeit von Prompts hängt von der Qualität der bereitgestellten Informationen und der Gestaltung des Prompts selbst ab. Prompts können Anweisungen, Fragen, kontextbezogene Details, Eingaben und Beispiele umfassen, um das Modell effektiv zu steuern und die Qualität der Ergebnisse zu verbessern. In diesem Dokument werden Strategien und Taktiken zur Optimierung der Leistung der Amazon Nova 2 Sonic-Modellfamilie beschrieben. Die hier vorgestellten Methoden können in verschiedenen Kombinationen angewendet werden, um ihre Wirksamkeit zu verstärken. Wir empfehlen Ihnen, zu experimentieren, um die Ansätze zu finden, die für ihre spezifischen Bedürfnisse am besten geeignet sind.

Erste Schritte mit Prompt Engineering

Bevor Sie mit dem Prompt-Engineering beginnen, empfehlen wir Ihnen, die folgenden Elemente bereitzustellen, damit Sie iterativ den für Ihren Anwendungsfall optimalen Prompt entwickeln können:

Definieren Sie Ihren Anwendungsfall

Definieren Sie Ihren Anwendungsfall in vier Dimensionen:

- **Aufgabe** — Definieren Sie, was das Modell erreichen soll. Dies bestimmt die richtige Eingabeaufforderungstechnik.
- **Rolle** — Definieren Sie, welche Rolle das Modell einnehmen soll, um die Aufgabe zu erfüllen. Amazon Nova-Modelle unterstützen drei Rollen (System, Benutzer oder Assistent).
- **Antwortstil** — Definieren Sie die Antwortstruktur oder den Stil, dem das Modell folgen soll, basierend auf der Zielgruppe, z. B. JSON, Markdown oder Konversation.
- **Anweisungen** — Definieren Sie die Anweisungen, die das Modell befolgen sollte, um die Erfolgskriterien zu erfüllen.

Legen Sie Erfolgskriterien fest

Definieren Sie Erfolgskriterien oder Bewertungskennzahlen. Sie können eine Kriterienliste oder spezifische Bewertungskennzahlen wie Länge, BLEU-Punktzahl, ROUGE, Format, Sachlichkeit und Treue angeben.

Verfassen Sie eine Aufforderung

Erstellen Sie eine Startaufforderung, die Ihre Aufgabe, Ihre Rolle, Ihren Antwortstil und Ihre Anweisungen enthält. Iterieren Sie auf der Grundlage der Ergebnisse.

Die Effektivität von Eingabeaufforderungen hängt von der Qualität der von Ihnen bereitgestellten Informationen ab.

Allgemeine bewährte Methoden

Die folgenden bewährten Methoden gelten hauptsächlich für die Amazon Nova-Textmodelle, Sie können sie jedoch zusätzlich zu den modalitätsspezifischen Best Practices auch auf andere Modelle anwenden.

Weitere Informationen zur Aufforderung multimodaler Eingaben finden Sie unter [Multimodale Eingaben veranlassen](#). Informationen zum Auffordern von Spracheingaben finden Sie [Eingabeaufforderungen für Sprachgespräche](#) unter.

Die Rollen verstehen

Amazon Nova-Modelle ermöglichen es Ihnen, Eingabeaufforderungen mithilfe von drei unterschiedlichen Rollen zu strukturieren: System, Benutzer und Assistent.

- System (optional) — Es ist zwar nicht verpflichtend, legt aber die allgemeinen Verhaltensparameter des Assistenten fest. Sie können auch verwendet werden, um zusätzliche Anweisungen und Richtlinien bereitzustellen, die das Modell während der gesamten Konversation einhalten soll.
- Benutzer — Kann optional den Kontext, die Aufgaben, Anweisungen und das gewünschte Ergebnis zusammen mit der Benutzerabfrage übermitteln.
- Assistent — Hilft dabei, das Modell zu der beabsichtigten Antwort zu führen.

Themen

- [Erstellen Sie präzise Eingabeaufforderungen](#)
- [Den Fokus auf Abschnitte des Prompts legen](#)
- [Die Systemrolle verwenden](#)
- [Geben Sie Beispiele \(Few-Shot-Prompting\)](#)
- [Systeme zum Aufrufen von Tools](#)
- [Fortgeschrittene Aufforderungstechniken](#)

Erstellen Sie präzise Eingabeaufforderungen

Die Erstellung spezifischer Benutzeranfragen ist für das Prompt-Engineering von entscheidender Bedeutung. Gut ausgearbeitete Abfragen leiten die Textverständnismodelle von Amazon Nova an, um genaue und sachdienliche Antworten zu generieren. Um solche Abfragen zu erstellen, ist es wichtig, zunächst Kontextinformationen in der Anfrage anzugeben. Der bereitgestellte Kontext trägt dazu bei, das Modell besser zu positionieren, indem es auf klare Zielnutzerszenarien ausgerichtet wird, wodurch die Relevanz und Kohärenz der Ergebnisse verbessert wird.

Bereitstellung kontextbezogener, spezifischer Informationen

Modelle funktionieren am besten, wenn die Anweisungen klar, gut strukturiert, kurz und spezifisch sind. Diese Anleitung für Prompt-Vorlagen gilt sowohl für den Benutzer-Prompt als auch für den System-Prompt.

Vorlage für schnelle Bearbeitung

```
# Use this to clearly define the task and job needed by the model
task_summary = f"""
## Task Summary:
```

```

{{Task summary}}
"""

# Use this to provide contextual information related to the task
context_information = f"""
## Context Information:
- {{Context and content information 1}}
- {{Context and content information 2}}
...
"""

# Use this to provide any model instructions that you want model to adhere to
model_instructions = f"""
## Model Instructions:
- {{ Other Model Instructions }}
...
"""

# Use this to provide response style and formatting guidance
response_style = f"""
## Response style and format requirements:
- {{Style and format requirement 1}}
- {{Style and format requirement 2}}
...
"""

# Concatenate to final prompt
final_prompt = f"""{{task_summary}}
{{context_information}}
{{model_instructions}}
{{response_style}}"""

```

Beispiel: Spezifische und kontextbezogene Informationen

Hier finden Sie ein Beispiel für einen Prompt, der mit spezifischen und Kontextinformationen neu geschrieben wurde. Das Hinzufügen weiterer Kontextinformationen hilft dem Modell, das gewünschte Verhalten zu erreichen.

Unclear prompt

User:

Write me a meeting invite to the project team

Assistant:

Certainly! Here's a sample meeting invite for your project team:

****Subject:**** Project Team Meeting - [Project Name]

****Date:**** [Insert Date]

****Time:**** [Insert Time]

****Duration:**** [Insert Duration]

****Location:**** [Insert Location] / [Zoom/Teams Link if Online]

****Agenda:****

1. ****Welcome and Introductions****

- Quick round of introductions for new team members

2. ****Project Overview****

- Objectives and goals
- Current status and milestones achieved

3. ****Task Allocation and Deadlines****

- Detailed breakdown of tasks
- Assignment of responsibilities
- Discussion of deadlines

4. ****Risk Management****

- Identification of potential risks
- Mitigation strategies

5. ****Resource Allocation****

- Required tools and materials
- Budget review

6. ****Q&A Session****

- Open floor for questions and clarifications

7. ****Next Steps and Closing****

- Summary of action items
- Schedule for the next meeting

****Additional Notes:****

- Please come prepared with any relevant documents or updates regarding your assigned tasks.
- If you anticipate any issues or require additional support, please let us know in advance so we can address them during the meeting.

****Contact Information:****

For any questions or concerns before the meeting, please feel free to reach out to [Your Name] at [Your Email] or [Your Phone Number].

We look forward to a productive discussion and to kicking off our project with enthusiasm!

Best regards,

[Your Full Name]

[Your Position]

[Your Contact Information]

Feel free to customize this template to better fit your specific project and team needs!

Clear prompt

User:

Write me a meeting invite to the project team. **The meeting is about project planning, and should be held on October 16th, from 10 AM to 11 AM in Conference Room B. Please include an agenda that covers our progress on the project thus far, as well as any upcoming milestones and deadlines.**

Assistant:

****Meeting Invitation: Project Planning Session****

****Date:**** October 16th

****Time:**** 10:00 AM - 11:00 AM

****Location:**** Conference Room B

****Agenda:****

1. ****Welcome and Introduction (10:00 AM - 10:05 AM)****
 - Brief overview by the meeting facilitator.
2. ****Project Progress Update (10:05 AM - 10:30 AM)****
 - Review of completed tasks and achievements to date.
 - Detailed discussion on current project status and any challenges encountered.
3. ****Upcoming Milestones and Deadlines (10:30 AM - 10:50 AM)****
 - Overview of the next phase of the project.
 - Identification of key milestones and deadlines.
4. ****Action Items and Responsibilities (10:50 AM - 11:00 AM)****
 - Assignment of tasks for the upcoming period.
 - Confirmation of individual responsibilities and follow-up items.
5. ****Q&A Session (11:00 AM)****
 - Open floor for any questions or concerns from team members.

Please ensure your attendance to discuss and finalize our project planning for the next phase. Your insights and contributions are highly valued.

Best regards,

[Your Name]

[Your Position]

[Your Contact Information]

- Seien Sie klar: Versuchen Sie beim Verfassen von Prompts für das Modell, die Anweisungen so klar wie möglich zu halten, wobei dies für Mensch und Maschine jeweils etwas anderes bedeutet (z. B. eine Liste im JSON-Stil).
- Seien Sie konkret: Geben Sie dem Modell genaue Anweisungen darüber, worin die Aufgabe besteht und was das erwartete Ergebnis ist, und liefern Sie zusätzliche Informationen, damit das Modell so reagiert, wie Sie es wünschen.

Ausgabeformat und den Stil angeben

Wenn Sie möchten, dass Amazon Nova 2 Antworten generiert, die auf Ihre spezifischen Bedürfnisse zugeschnitten sind, können Sie das Format und den Stil der Ausgabe angeben. Zum Beispiel, wenn Sie Antworten nur in JSON generieren oder die Antwortlänge auf eine maximale Anzahl von Wörtern, Aufzählungspunkten oder Absätzen beschränken möchten. Auf diese Weise kann Amazon Nova 2

Ihre Anforderungen besser verstehen und eine relevantere und leichter zu analysierende Ausgabe erstellen.

Verwenden Sie Großbuchstaben und starke Formulierungen wie „TUN“, „NICHT TUN“, „MUSS“, um die Regeln hervorzuheben, die das Modell strikt einhalten soll. Wenn Sie beispielsweise nur ein JSON-Objekt in der Antwort haben möchten, können Sie das Modell anweisen, indem Sie sagen: „Du MUSST im JSON-Format antworten. Verwende bei der Beantwortung der Frage KEIN anderes Format.“

Hier sind einige Beispiel-Prompts, die mit spezifischen und kontextbezogenen Informationen umgeschrieben wurden. Das Hinzufügen weiterer Kontextinformationen hilft dem Modell, das gewünschte Verhalten zu erreichen.

Beispiel 1: Geben Sie zusätzliche Details an

Das Hinzufügen zusätzlicher Details zur Formatierung der Antwort kann dem Modell helfen, das gewünschte Ergebnis zu erzielen. Zu den anderen häufig verwendeten Antwortformaten gehören CSV, Markdown, YAML und XML

Prompt without style constraints

User:

Outline the different types of rooms available in a typical 4-star hotel, including their features.

Assistant:

In a typical 4-star hotel, you'll find a range of room types, each designed to cater to different guest needs and preferences. Here's an outline of the different types of rooms available along with their features:

1. **Standard Room**

- **Size:** Usually around 250-350 square feet.
- **Features:**
 - Queen or double bed.
 - Complimentary Wi-Fi.
 - Flat-screen TV with cable or satellite channels.
 - Mini-fridge.
 - Coffee maker with complimentary coffee and tea.
 - Desk and chair.
 - En-suite bathroom with shower, toilet, and toiletries.

- Air conditioning/heating.

2. **Deluxe Room**

- **Size:** Typically larger than standard rooms, around 350-450 square feet.
- **Features:**
 - King bed or two queen beds.
 - Larger bathroom with a bathtub.
 - Additional seating area.
 - Enhanced amenities like bathrobes and slippers.
 - Upgraded toiletries and sometimes a welcome gift.
 - Access to a lounge or executive floor perks.

3. **Suite**

- **Size:** Varies significantly, often between 500-1,200 square feet.
- **Features:**
 - Separate living area with a sofa bed or additional seating.
 - Kitchenette or full kitchen in some cases.
 - Larger, more luxurious bathroom with a bathtub and separate shower.
 - Multiple TVs.
 - Access to executive lounge.
 - High-end toiletries and often complimentary breakfast.
 - Often includes concierge services and in-room dining options.

4. **Family Room**

- **Size:** Larger, usually around 400-500 square feet.
- **Features:**
 - One king bed and one sofa bed or two queen beds.
 - Designed for families with children.
 - Extra space for luggage.
 - Child-friendly amenities like a small kitchenette or high chair.
 - Family bathroom with amenities suitable for kids.

5. **Executive Room**

- **Size:** Typically around 350-450 square feet.
- **Features:**
 - Business-oriented with a larger workspace.
 - Executive desk and chair.
 - Access to executive lounge with complimentary snacks and refreshments.
 - King bed or two queen beds.
 - Enhanced amenities like high-speed internet and sometimes a Nespresso machine.

6. **Junior Suite**

- **Size:** Usually around 450-600 square feet.
- **Features:**

- Separate bedroom and living area.
- King bed or two queen beds.
- Kitchenette or mini-fridge.
- Luxurious bathroom with a bathtub.
- Lounge access.
- High-end toiletries.

7. **Premium Room**

- **Size:** Larger than standard rooms, around 400-500 square feet.
- **Features:**
 - King bed or two queen beds.
 - Larger bathroom with a bathtub.
 - Enhanced amenities like a welcome drink and premium toiletries.
 - Access to premium services and sometimes a lounge.

8. **Connecting Rooms**

- **Size:** Two rooms that connect via an internal door.
- **Features:**
 - Suitable for families or groups.
 - Often includes one standard room and one suite.
 - Shared bathroom or en-suite bathrooms in each room.
 - Extra space for luggage and guests.

9. **Accessible Rooms**

- **Size:** Varies, typically similar to standard rooms.
- **Features:**
 - Designed for guests with disabilities.
 - Wider doorways and bathroom space.
 - Adapted fixtures and fittings.
 - Additional support services.

10. **Business Room**

- **Size:** Usually around 300-350 square feet.
- **Features:**
 - Focused on business travelers.
 - High-speed internet and large workspace.
 - Compact yet fully equipped with essentials.
 - Often includes a king bed.

Each room type in a 4-star hotel is designed to provide comfort, convenience, and luxury tailored to different guest needs, ensuring a pleasant stay for all types of travelers.

Prompt with style constraints

User:

Outline the different types of rooms available in a typical 4-star hotel, including their features. **All responses MUST be in YAML format.**

Assistant:

```
```yaml
hotel_rooms:
 - room_type: Standard Room
 features:
 - description: A comfortable room with essential amenities.
 amenities:
 - bed_type: Double bed or two single beds
 - bathroom: Private bathroom with shower
 - wifi: Complimentary high-speed internet
 - TV: Flat-screen TV with cable channels
 - mini_fridge: Available
 - tea_and_coffee_making_facilities: Yes

 - room_type: Deluxe Room
 features:
 - description: An upgraded room with more space and enhanced amenities.
 amenities:
 - bed_type: King-size bed or two single beds
 - bathroom: Private bathroom with both shower and bathtub
 - wifi: Complimentary high-speed internet
 - TV: Larger flat-screen TV with cable channels
 - mini_fridge: Available
 - tea_and_coffee_making_facilities: Yes
 - free_breakfast: Included

 - room_type: Suite
 features:
 - description: A luxurious room with separate living area and premium amenities.
 amenities:
 - bed_type: King-size bed or two single beds
 - bathroom: Private bathroom with both shower and bathtub
 - separate_living_area: Yes
 - wifi: Complimentary high-speed internet
 - TV: Large flat-screen TV with cable channels
```

```

- mini_fridge: Available
- tea_and_coffee_making_facilities: Yes
- free_breakfast: Included
- concierge_service: Available

- room_type: Family Room
features:
- description: A spacious room designed for families with additional bedding
options.
amenities:
- bed_type: Queen bed and rollaway bed or two single beds and rollaway bed
- bathroom: Private bathroom with shower
- wifi: Complimentary high-speed internet
- TV: Flat-screen TV with cable channels
- mini_fridge: Available
- tea_and_coffee_making_facilities: Yes

- room_type: Business Room
features:
- description: A room tailored for business travelers with enhanced workspace.
amenities:
- bed_type: Double bed or two single beds
- bathroom: Private bathroom with shower
- wifi: Complimentary high-speed internet
- TV: Flat-screen TV with cable channels
- workspace: Desk and chair
- mini_fridge: Available
- tea_and_coffee_making_facilities: Yes
- business_center_access: Available
```

```

Beispiel 2: Geben Sie Stileinschränkungen an

In diesem Fall bietet der Prompt mit den Stileinschränkungen umfassende Informationen zu den einzuhaltenden Einschränkungen und zum gewünschten Antwortformat. Wie in der Antwort festgestellt wurde, entspricht der optimierte Prompt eher der geforderten Kürze und der Struktur der Aufzählung.

Prompt without style constraints

User:

Explain the process of checking in a guest at a luxury resort.

Assistant:

Checking in a guest at a luxury resort involves a meticulous and personalized process designed to ensure a seamless and memorable start to their stay. Here's a detailed overview of the steps involved:

Pre-Arrival Preparation

1. ****Pre-Arrival Communication:****

- ****Confirmation:**** Verify guest reservations and confirm arrival details.
- ****Special Requests:**** Collect any special requests (dietary restrictions, room preferences, etc.) and ensure they are noted in the guest profile.
- ****Documentation:**** Ensure all necessary documentation is ready, such as welcome letters, room keys, and any special amenities.

2. ****Room Preparation:****

- ****Cleaning:**** Conduct a thorough cleaning and preparation of the guest room.
- ****Amenities:**** Stock the room with high-end toiletries, fresh linens, and any requested amenities.
- ****Personal Touches:**** Add personalized touches such as a welcome note, fresh flowers, or locally sourced treats.

Arrival and Initial Interaction

3. ****Guest Arrival:****

- ****Greeting:**** Have staff ready to greet guests as they arrive. This may include a warm welcome at the entrance or a meet-and-greet in the lobby.
- ****Transport:**** Provide luxury transport options like a chauffeured car service to escort guests to the check-in desk.

4. ****Check-In Desk:****

- ****Professionalism:**** Ensure check-in staff are well-trained, professional, and exude hospitality.
- ****Technology:**** Utilize sophisticated check-in technology (like tablet kiosks) to streamline the process.
- ****Personalized Welcome:**** Greet guests with a warm welcome, acknowledge their special requests, and present them with a personalized welcome kit.

Documentation and Formalities

5. ****Document Verification:****

- ****Identification:**** Verify identification and payment methods.
- ****Membership Cards:**** If applicable, verify any loyalty or membership cards for additional benefits.

6. ****Registration:****

- ****Form Filling:**** Assist guests with any required paperwork.
- ****Special Benefits:**** Clearly explain any special resort benefits, upgrades, or exclusive access to amenities that the guest is entitled to.

Room Assignment

7. ****Room Presentation:****

- ****Walk-Through:**** Escort guests to their room and conduct a walk-through to ensure everything is in order and to address any immediate concerns.
- ****Upgrades:**** Present any room upgrades and explain the features and services available in the upgraded room.

8. ****Key Delivery:****

- ****Room Key:**** Provide the room key, often a high-end key card or a luxury key fob.
- ****Access Information:**** Explain how to use the key card, including access to other amenities like the spa, pool, and gym.

Additional Services

9. ****Welcome Amenities:****

- ****Amenity Kits:**** Deliver welcome amenity kits (like a bottle of champagne, local delicacies, etc.).
- ****Itinerary:**** Provide a detailed resort map and itinerary, highlighting all available services and activities.

10. ****Personal Concierge:****

- ****Concierge Services:**** Introduce the guest to the concierge service and explain how to request any special services, such as dining reservations, transportation, or local excursions.
- ****Contact Information:**** Provide contact information for key staff members.

Final Touches

11. ****Feedback:****

- ****Satisfaction Survey:**** At the end of the check-in process, ask for feedback to ensure the guest's expectations were met and to gather any immediate suggestions.

12. ****Follow-Up:****

- ****Immediate Issues:**** Ensure any immediate issues or requests are addressed promptly.
- ****Comfort Check:**** Make follow-up calls or send messages to ensure the guest is settling in comfortably.

By following these steps, a luxury resort aims to provide an exceptional check-in experience that sets the tone for an unforgettable stay.

Prompt with style constraints

User:

Explain the process of checking in a guest at a luxury resort. **Provide all answers in a numbered list format, with each point containing no more than 15 words, and no more than 6 bullet points.**

Assistant:

1. Greet guest warmly with a smile and offer assistance.
2. Verify reservation details and check guest's identification.
3. Confirm room assignment and amenities provided.
4. Explain resort services and amenities available.
5. Present room key and offer directions to guest's suite.
6. Wish guest a pleasant stay and be available for queries.

Beispiel 3: Beschränken Sie das Antwortformat

Hier zwingt der Prompt das Modell mit dem Antwortformat, nur mit der Kategoriennummer zu antworten und sie auf einen Wert zwischen 1 und 10 zu beschränken, anstatt sehr ausführlich zu sein.

Prompt without response format

User:

In this task, you are given a text which is the body of a document. Your job is to classify the topic of the document into these categories: 1)Company, 2)Educational Institution, 3)Artist, 4)Athlete, 5)Office Holder, 6)Mean of transportation, 7)Building, 8)Natural place, 9)Village, 10)Animal.
Text: Johangsan is a mountain of South Korea. It has an elevation of 954 metres.

Assistant:

To classify the topic of the given text, let's analyze the content step-by-step:

1. The text mentions "Johangsan," which appears to be a specific name.
2. The text states that "Johangsan is a mountain," which provides a clear indication of its nature.
3. It is further specified that it is located in "South Korea" and has an elevation of "954 metres."

Based on the information provided, the text describes a geographical feature, specifically a mountain. From the given categories, the most appropriate classification for this document is:

8) Natural place

The text does not mention any company, educational institution, artist, athlete, office holder, means of transportation, building, village, or animal. Therefore, the classification as a "Natural place" is the most fitting choice.

Prompt with response format

User:

In this task, you are given a text which is the body of a document. Your job is to classify the topic of the document into these categories: 1)Company, 2)Educational Institution, 3)Artist, 4)Athlete, 5)Office Holder, 6)Mean of transportation, 7)Building, 8)Natural place, 9)Village, 10)Animal. **Your output should be the category number. DO NOT generate anything apart from numbers 1-10.**

Text: Johangsan is a mountain of South Korea. It has an elevation of 954 metres.

Assistant:

8

Stellen Sie klare Prompt-Abschnitte bereit

Über den ursprünglichen Kontext hinaus spielt ein strukturiertes Abfrageformat eine wichtige Rolle bei der Optimierung der Interaktionen mit dem Sprachmodell. Die Trennung verschiedener Teile der Eingabe durch Trennzeichen sorgt für Klarheit und verbessert die Fähigkeit der Amazon Nova 2-Modelle, die Struktur der Abfrage zu verstehen. Eine weitere effektive Methode ist die Verwendung

von nummerierten Listen oder Aufzählungspunkten, die dazu beitragen können, die Aufgabe in überschaubare Schritte zu unterteilen und einen klaren Überblick über die zu ergreifenden Maßnahmen zu geben. Dieser strukturierte Ansatz trägt dazu bei, Unklarheiten zu verringern und die Genauigkeit der generierten Antworten zu verbessern.

Beispiel: Erstellen Sie einen Prompt mit Abschnitten

Beachten Sie, dass in der Spalte „Unterteilter Prompt“ der Prompt klarer ist und im Vergleich zu den Anweisungen in der Spalte „Nicht unterteilter Prompt“ abgegrenzte Abschnitte für verschiedene Elemente wie Aufgaben, Kontext, Anforderungen und den Rest enthält.

Unsectioned Prompt

User:

Write an article about climate change for high school students explaining basic concepts, current impacts, and individual actions to mitigate it. Make it informative and engaging with simple language, including statistics and real-world examples.

Assistant:

Understanding Climate Change: What It Is, What It's Doing, and What You Can Do About It

Introduction

Climate change might sound like a big, complicated topic, but it's really about the way our planet's weather is changing over time. This change is mostly happening because humans are doing things that are making our Earth warmer. Let's break it down so you can understand what's going on and what you can do to help.

What Is Climate Change?

Climate change refers to long-term shifts in temperatures and weather patterns. These shifts may be natural, but since the 1800s, human activities have been the main driver of rapid climate change.

Key Concept: Greenhouse Gases

To understand this, we need to talk about greenhouse gases. These gases, like carbon dioxide (CO₂), methane (CH₄), and nitrous oxide (N₂O), trap heat in our atmosphere. Without these gases, Earth would be too cold for most life forms. But when we burn fossil fuels (like coal, oil, and natural gas) and cut down forests, we release too much CO₂ and other greenhouse gases, trapping more heat and making the planet warmer.

Current Impacts of Climate Change

Let's look at some real-world examples to see how climate change is affecting our world today.

1. Rising Temperatures

Since the late 19th century, Earth's average surface temperature has risen about 2 degrees Fahrenheit (1 degree Celsius). Scientists predict that if we don't change our ways, it could rise by 3.6 to 4.3 degrees Fahrenheit (2 to 2.4 degrees Celsius) by the end of this century.

2. More Extreme Weather

Climate change is making extreme weather events more frequent and severe. For example:

- **Hurricanes:** In the U.S., hurricane seasons are getting longer and more destructive. In 2020, there were 30 named storms, the most ever recorded.
- **Droughts:** Parts of California have experienced some of the worst droughts in history, affecting agriculture and water supplies.

3. Melting Ice Caps and Rising Sea Levels

Glaciers and ice sheets are melting at alarming rates. This not only affects wildlife but also leads to rising sea levels. Since 1901, global sea levels have risen by about 8 inches (20 centimeters). By 2100, they could rise by another 1 to 4 feet (0.3 to 1.2 meters).

4. Ocean Acidification

As CO2 levels rise, more of it is absorbed by the oceans, making them more acidic. This is particularly harmful to marine life, including coral reefs. Coral reefs are crucial for marine biodiversity but are now dying at an alarming rate.

Individual Actions to Mitigate Climate Change

You might think that since climate change is a huge problem, one person can't make a difference. But even small actions can add up to make a big impact.

1. Reduce, Reuse, Recycle

Try to minimize waste by:

- **Reducing:** Buy fewer items and choose products with less packaging.
- **Reusing:** Use reusable bags, bottles, and containers.
- **Recycling:** Make sure to recycle paper, plastic, and glass properly.

2. Conserve Energy

Small changes can lead to big savings:

- Turn off lights when you leave a room.
- Unplug devices that you're not using.

- Use energy-efficient bulbs and appliances.

****3. Use Less Meat****

Livestock farming is a major contributor to greenhouse gas emissions. By eating less meat, especially beef, you can reduce your carbon footprint.

****4. Support Renewable Energy****

If possible, support or switch to renewable energy sources like solar or wind power. Even advocating for these options in your community can make a difference.

****5. Educate Yourself and Others****

Knowledge is power. The more you know about climate change, the more you can help others understand it. Share facts and encourage your friends and family to take action too.

Conclusion

Climate change is a pressing issue that affects everyone on the planet. By understanding its basics, recognizing its current impacts, and taking individual actions, you can play a crucial role in mitigating its effects. Remember, every small step counts, and together, we can make a big difference for our planet.

Let's start today and build a sustainable future!

Sectioned Prompt

User:

****Task:****

Write an article

****Context Section:****

Topic: Climate Change

Target Audience: High School Students

Purpose: Educational Article

****Content Requirements:****

- Explanation of basic concepts related to climate change.
- Examples of current impacts on ecosystems and human populations.
- Suggestions for individual actions to mitigate climate change.

****Tone and Style:****

- Informative and engaging
- Use simple language

- Include statistics and real-world examples

Assistant:

Understanding Climate Change: A Guide for High School Students

Introduction

Climate change is one of the most pressing issues of our time. It affects our planet, our ecosystems, and our daily lives. Understanding what climate change is and how it impacts us can help us take action to make a difference. This article will explain the basic concepts of climate change, provide examples of its current impacts, and suggest actions you can take to help mitigate it.

What is Climate Change?

Climate change refers to long-term changes in global temperatures and weather patterns. These changes are primarily caused by human activities, especially the burning of fossil fuels like coal, oil, and natural gas. When we burn these fuels, we release large amounts of greenhouse gases, such as carbon dioxide (CO₂) and methane (CH₄), into the atmosphere. These gases trap heat from the sun, causing the Earth's temperature to rise. This is often referred to as the **greenhouse effect**.

Basic Concepts:

- Greenhouse Gases**: These gases include carbon dioxide, methane, nitrous oxide, and fluorinated gases. They trap heat in the Earth's atmosphere.
- Global Warming**: This is the increase in Earth's average surface temperature due to rising levels of greenhouse gases.
- Climate Change**: Refers to the broader set of changes in the Earth's climate system, including global warming.

Current Impacts of Climate Change

On Ecosystems:

- Melting Ice Caps and Glaciers**: The polar ice caps and glaciers are melting at an alarming rate. For example, the Arctic sea ice is shrinking, which affects polar bears and other Arctic animals.

2. **Rising Sea Levels**: As ice melts, sea levels rise. This can lead to the loss of coastal habitats and increased flooding in coastal areas.

3. **Changing Weather Patterns**: Climate change can lead to more frequent and severe weather events such as hurricanes, droughts, and heatwaves. For example, the 2020 Australian bushfires were more intense and lasted longer than usual due to climate change.

On Human Populations:

1. **Health Issues**: Rising temperatures can lead to more heat-related illnesses and the spread of diseases like malaria and dengue fever.

2. **Food Security**: Changes in climate can affect crop yields, leading to food shortages. For example, droughts in Sub-Saharan Africa have caused significant food insecurity.

3. **Displacement**: Rising sea levels and extreme weather events can force people to leave their homes, becoming climate refugees. For instance, communities in Bangladesh are being displaced by rising sea levels.

Actions You Can Take

Even though climate change is a massive issue, there are many actions you can take to help mitigate its effects. Here are some simple steps you can start with today:

1. **Reduce, Reuse, Recycle**: By reducing waste, reusing items, and recycling, you can decrease the amount of trash that ends up in landfills and reduce greenhouse gas emissions.

2. **Save Energy**: Turn off lights when you don't need them, use energy-efficient appliances, and unplug devices when they're not in use. These small actions can make a big difference.

3. **Use Less Meat**: Livestock farming produces a significant amount of methane. By eating less meat, particularly beef, you can reduce your carbon footprint.

4. **Support Renewable Energy**: Advocate for or invest in renewable energy sources like solar and wind power. These sources produce energy without greenhouse gas emissions.

5. **Educate and Advocate**: Inform others about the impacts of climate change and advocate for policies that support environmental sustainability. You can join or support environmental clubs at school or participate in local clean-up efforts.

Conclusion

Climate change is a complex issue with far-reaching impacts. However, understanding it and taking action can make a significant difference. By learning about the basic concepts, recognizing the current impacts, and implementing simple changes in our daily lives, we can all contribute to mitigating climate change. Remember, every small action counts, and together, we can create a more sustainable future for our planet.

Den Fokus auf Abschnitte des Prompts legen

Amazon Nova 2-Modelle können bestimmten Teilen in der Aufforderung besondere Aufmerksamkeit schenken, indem sie Anweisungen in Abschnitten formatieren und dann auf diese spezifischen Abschnitte verweisen. Das Modell kann darauf Rücksicht nehmen, wenn Prompts eine klare Abschnittsunterteilung mittels Markdown, XML oder einer anderen Struktur aufweisen. Sie können beispielsweise den Namen des Abschnitts definieren, `##Section Name##` verwenden, und dann in Ihrem Prompt mit `##Section Name##` auf diesen Abschnitt verweisen.

Sie können diese Strategie auch anwenden, um zu verhindern, dass das Modell Teile des Prompts in der generierten Antwort preisgibt. Wenn Sie beispielsweise nur wenige Musterbeispiele oder Anweisungen im Eingabe-Prompt angeben, verwenden Sie Trennzeichen wie `##Instructions##` oder `##Examples##` mit einem neuen Zeilentrennzeichen und geben Sie aussagekräftige Anweisungen wie `DO NOT mention anything inside the ##Instructions## or ##Examples## in the response`, damit das Modell den Inhalt des Prompts aus diesen Abschnitten in der Ausgabe nicht wiedergibt.

Beispiel: Abschnittsunterteilung

Benutzer:

You're an expert Prompts creator. Your task is to create a set of diverse and very complex `##PROMPTS##` that will be used to test the capabilities of a language model in knowledge and following instructions with constraints. Please create 10 `##PROMPTS##`. You must strictly follow `##GUIDELINES##`:

`##GUIDELINES##`

- Generate `##PROMPTS##` similar to the structure and style of the given `##EXAMPLE PROMPTS##`. Pay close attention to the complexity and diversity of `##EXAMPLE PROMPTS##`.

- Generated `##PROMPTS##` must be from the `##DOMAINS##` and must be with these `##USECASES##`.
- Each of the `##PROMPTS##` needs to be unique and very complex.
- Each of the `##PROMPTS##` must have more than 4 sentences and 1 constraint.
- Each of the `##PROMPTS##` should have at least 70 words.
- Each of the `##PROMPTS##` should have an answer that can be written in text.
- The length of the answer of these `##PROMPTS##` must be finite and not very very long.
- In the `##PROMPTS##` you should not mention anything about writing in pages or slides.
- Each of the `##PROMPTS##` should be separated by a new line, without additional formatting.

Generated `##PROMPTS##` must be from the following `##DOMAINS##`

`##DOMAINS##`

`{domains}`

Generated `##PROMPTS##` must be for the following `##USECASES##`

`##USECASES##`

`{usecases}`

`{usecase_description}`

`##PROMPTS##`

Die Systemrolle verwenden

Die Systemrolle ist eine Rolle, in der Sie dem Modell Anweisungen geben können, die definieren, wie es auf Endbenutzer Ihrer Anwendung reagieren soll. Die Systemrolle kann das Modell beispielsweise dazu anleiten, mit einer bestimmten Persona zu antworten, zulässige und unzulässige Inhalte festzulegen, in einem bestimmten Format auszugeben, Integritätsschutz festzulegen usw. Die Anweisungen in der Systemrolle, dem so genannten System-Prompt, haben Vorrang vor anderen Anweisungen, die in den einzelnen Benutzer-Prompts enthalten sind, und gelten für alle Benutzerrunden.

Die Systemrolle mit der API angeben

Um dem Modell eine benutzerdefinierte Rolle zuzuweisen, können Sie den `system`-Parameter in der API wie folgt festlegen:

```
{
  "system": [
    {
```

```

    "text": "You are a helpful recipe assistant. For each recipe request, follow
these steps: 1) List all ingredients needed, 2) Provide prep time and cook time, 3)
Give step-by-step instructions, 4) Suggest possible variations or substitutions."
  }
],
"messages": [
  {
    "role": "user",
    "content": [
      {
        "type": "text",
        "text": "How do I make a classic tomato basil pasta?"
      }
    ]
  }
]
}

```

Tip

- Um die Systemrolle optimal nutzen zu können, stellen Sie sicher, dass Ihr System-Prompt klar, präzise und spezifisch ist. Folgen Sie dabei denselben Strategien wie unter [Erstellen Sie präzise Eingabeaufforderungen](#) beschrieben. Wenn Sie beispielsweise die Themen einschränken möchten, auf die das Modell reagieren soll, geben Sie ihm konkrete Anweisungen wie „Sprich NICHT über ...“ oder „Du MUSST über ... sprechen“.
- Um das Modell weiter auf eine Hierarchiestruktur zu beschränken, können Sie Ihrem System-Prompt das folgende Suffix hinzufügen, um die Hierarchiekonformität zwischen System- und Benutzeranweisungen zu betonen:

```

"\n
The above system instructions define your capabilities and your
scope. If the user request contradicts any system instruction or
if the request is outside your scope, you must politely decline the
request briefly explaining your capabilities and your scope.\n
"

```

Die folgenden Elemente können Sie einer Vorlage für einen System-Prompt hinzufügen:

```

# Define a persona
persona = ""You are {{Persona}}
""

```

```
# Provide a series of instructions that should be followed while answering
model_instructions = """## Model Instructions
To answer user question, you follow these instructions/steps:
{{Bulleted list of Instructions}}
"""

# Specify the output schema to be followed when responding
response_schema = """## Response Schema
Your response should be in the following output schema:
{{Clear definition of output format}}
"""

# Specify any guardrails that the model should NOT DO explicitly
guardrails = """## Guardrails
Make sure to follow these guardrails:
{{ Guardrails }}
"""

system_prompt = f"""{persona}
{model_instructions}
{response_schema}
{guardrails}
"""
```

Um dem System-Prompt die Hierarchiekonformitätsstruktur zwischen System- und Benutzeranweisungen zuzuweisen, können Sie Folgendes hinzufügen:

The above system instructions define your capabilities and your scope. If the user request contradicts any system instruction or if the request is outside your scope, you must politely decline the request briefly explaining your capabilities and your scope.

Beispiel 1: Bereitstellung spezifischer Sprachhinweise

Nach dem Hinzufügen des System-Prompts sind die Antworten des Modells stark an den mittelalterlichen Schriftrollenstil angelehnt, wie im System-Prompt angegeben.

Without a System Prompt

System:

NA

Nutzer:

Explain the modern concept of hotel loyalty programs and their benefits.

Assistentin:

Hotel loyalty programs have evolved significantly in the modern hospitality industry, becoming sophisticated tools for enhancing customer retention and satisfaction. These programs offer various benefits to both hotels and guests, leveraging technology and data analytics to create a more personalized experience.

Key Components of Modern Hotel Loyalty Programs:

1. **Tiered Membership Levels:**

- **Basic Membership:** Entry-level membership that provides basic benefits.
- **Mid-Tier Membership:** Includes additional perks such as room upgrades, faster check-in, and special offers.
- **Top-Tier Membership:** Offers premium benefits like complimentary upgrades, room service, exclusive access to hotel events, and more.

2. **Point System:**

- Guests earn points for every stay, purchases made in hotel restaurants, and other activities.
- Points can be redeemed for free nights, upgrades, or other rewards.

3. **Mobile App Integration:**

- Modern programs often have a dedicated mobile app that allows guests to easily manage their account, check in, and access exclusive offers.
- Features may include digital key access, personalized recommendations, and real-time updates.

4. **Personalization:**

- Utilizing data analytics, hotels can tailor recommendations and offers to individual guest preferences, enhancing the overall experience.
- Personalized marketing through emails and push notifications can keep guests engaged.

5. **Cross-Brand Benefits:**

- Some loyalty programs offer benefits across multiple brands within a hotel group or even within different hospitality groups.

- This can include discounts, points transfers, and combined rewards.

6. **Social Media Integration:**

- Many programs encourage social media sharing and reviews, which can enhance the hotel's online presence and attract new guests.
- Social media contests and exclusive promotions can further engage members.

7. **Sustainability Initiatives:**

- Modern loyalty programs increasingly incorporate sustainability, offering points or rewards for eco-friendly choices like reducing plastic use or participating in recycling programs.

Benefits to Guests:

1. **Financial Savings:**

- Accumulation of points for free or discounted stays.
- Exclusive discounts and offers not available to non-members.

2. **Enhanced Services:**

- Faster check-in, preferred room assignments, and personalized services.
- Access to exclusive events and experiences.

3. **Convenience:**

- Easy booking and management through mobile apps.
- Seamless integration with other services like car rentals and travel packages.

4. **Recognition and Prestige:**

- Status symbols like elite membership levels.
- Recognition by hotel staff and priority service at participating properties.

Benefits to Hotels:

1. **Increased Guest Loyalty:**

- Encourages repeat visits and long-term relationships with guests.
- Helps retain customers even when faced with competition.

2. **Data Collection and Analysis:**

- Provides valuable insights into guest preferences and behaviors.
- Helps hotels tailor their services and marketing strategies effectively.

3. **Revenue Growth:**

- Drives up room occupancy and average daily rate (ADR) through repeat business.
- Cross-selling opportunities within the hotel (e.g., dining, spa services).

4. **Market Differentiation:**

- Helps hotels stand out in a competitive market.
- Offers a unique selling proposition that attracts brand-loyal customers.

Conclusion:

Modern hotel loyalty programs have become a critical component of the hospitality industry, leveraging technology and data to create personalized, engaging, and rewarding experiences for guests. They provide significant benefits to both guests, who enjoy enhanced services and savings, and hotels, which gain deeper insights and increased revenue through stronger customer relationships.

With a System Prompt

System:

Provide answers in the style of a medieval scroll, using old English vocabulary and phrases.

Nutzer:

Explain the modern concept of hotel loyalty programs and their benefits.

Assistentin:

Here followeth a detailed exposition of the modern concept known as hotel loyalty programs, penned in the venerable style befitting such an arcane and wondrous subject.

In the annals of contemporary hostelry and inns, there doth exist a most wondrous construct termed "hotel loyalty programs." These programs be akin to the ancient covenants or oaths betwixt lord and vassal, binding patrons unto the establishments in which they sojourn.

Loyalty programs doth grant unto the faithful patrons, known as members, manifold benefits and rewards of great magnanimity. These benefactions are bestowed through the accumulation of points or credits, garnered by sojourns and patronage. Herein lieth the essence of the program: the more one sojourneth, the more points they dost garner, which may then be exchanged for sundry rewards.

The benefits of these programs are manifold and most enticing:

1. ****Frequent Stayer Privileges****: Members may find themselves accorded preferential treatment, such as elevated room categories or enhanced services, akin to the favors granted by a noble unto his most loyal swain.
2. ****Accelerated Status****: In this modern hierarchy, members may ascend to exalted tiers, each tier granting more bountiful privileges. Such tiers may include titles of honor such as "Silver," "Gold," or even "Platinum," bestowing upon the member increased perks with each ascension.
3. ****Free Nights and Services****: Verily, members may claim nights of lodging without the burden of coin, akin to the boons granted by a generous lord to his steadfast followers. Additionally, sundry services such as complimentary breakfasts or room upgrades may be offered.
4. ****Special Offers and Discounts****: Members might also receive secret and special offers, as if privy to the most intimate counsels of the innkeeper, granting them discounts and other boons not afforded to the common patron.
5. ****Personalized Experience****: The programs often tailor their services to the preferences and habits of their members, much like a wise steward who remembers the tastes and whims of his lord.

Thus, in the realm of modern hostelry, the hotel loyalty program standeth as a testament to the virtues of faithfulness and patronage, offering unto its adherents a tapestry of rewards and benefits that doth rival the most storied legends of old.

Beispiel 2: Bereitstellung von Leitplanken

Mit dem System-Prompt können Benutzer Integritätsschutz für ihre Anwendungen hinzufügen, um die Anwendungen vor unbeabsichtigter Verwendung zu schützen. Hier ist ein Beispiel dafür, wie Leitplanken das Modell auf die gewünschte Aufgabe ausrichten können.

Without a System Prompt

System:

NA

Nutzer:

Write a one-page business plan for a cooperative bike-sharing program in urban centers aiming to lower traffic congestion and promote eco-friendly transportation.

(Include target markets, revenue streams, marketing strategy, and risk mitigation plans.)

Assistentin:

****Urban EcoCycle: A Cooperative Bike-Sharing Program****

****Executive Summary:****

Urban EcoCycle is a cooperative bike-sharing program designed to alleviate traffic congestion and promote eco-friendly transportation in urban centers. By providing accessible, affordable, and convenient bike-sharing services, we aim to foster a sustainable urban mobility ecosystem that benefits both residents and the environment.

****Target Markets:****

Our primary target markets include urban professionals, students, and environmentally conscious citizens. We also aim to attract tourists looking for an affordable and eco-friendly way to explore the city. Secondary markets will include local businesses that could benefit from reduced employee commuting times and increased customer engagement due to the program's presence.

****Revenue Streams:****

1. ****Subscription Fees:**** Monthly or yearly subscription plans for individuals and businesses.
2. ****Ad Revenue:**** Partnerships with local businesses for advertising space on bikes and docking stations.
3. ****Corporate Partnerships:**** Collaborations with companies to provide their employees with access to our bike-sharing program.
4. ****Government Grants:**** Applications for grants and subsidies from local government initiatives aimed at promoting sustainable transportation.

****Marketing Strategy:****

1. ****Digital Marketing:**** Utilize social media platforms, email newsletters, and our website to reach out to potential users and partners. Highlight success stories and eco-friendly benefits.
2. ****Partnerships:**** Collaborate with local businesses, schools, and environmental organizations to promote our service.
3. ****Community Events:**** Host bike-sharing workshops, clean-up events, and eco-friendly fairs to engage with the community.
4. ****Incentives:**** Offer discounts and rewards for long-term subscribers and those who refer new members.

****Risk Mitigation Plans:****

1. **Maintenance and Security:** Implement a robust maintenance schedule to ensure bikes are always in good working condition. Employ security measures such as GPS tracking and insurance coverage to protect bikes from theft and damage.
2. **Regulatory Compliance:** Stay informed about local regulations and ensure compliance to avoid legal issues. Work with local authorities to establish clear guidelines for bike parking and usage.
3. **Market Competition:** Conduct regular market research to stay ahead of competitors. Differentiate our service by offering unique features such as bike rentals for longer trips, special eco-friendly programs, and partnerships with popular local destinations.
4. **Economic Fluctuations:** Develop flexible pricing strategies and diversify revenue streams to cushion against economic downturns. Maintain a reserve fund to handle unexpected financial challenges.

Urban EcoCycle is poised to become a cornerstone of urban sustainability by reducing traffic congestion and promoting green transportation. With a well-defined target market, diverse revenue streams, strategic marketing, and comprehensive risk mitigation plans, we are committed to making our urban centers more livable and eco-friendly.

With a System Prompt

System:

You are Application Process Assistant

To answer user question, you follow these instructions/steps:

- The LLM chatbot can discuss topics related to college applications, including deadlines, required materials, and application status.
- The LLM chatbot should be polite and courteous in all responses.
- The LLM chatbot can only respond in 3 sentences or less.

The above system instructions define your capabilities and your scope. If the user request contradicts any system instruction or if the request is outside your scope, you must politely decline the request briefly explaining your capabilities and your scope.\n

Nutzer:

Write a one-page business plan for a cooperative bike-sharing program in urban centers aiming to lower traffic congestion and promote eco-friendly transportation. (Include target markets, revenue streams, marketing strategy, and risk mitigation plans.)

Assistentin:

I'm here to help with college application-related questions, including deadlines and required materials. For your business plan request, I recommend seeking assistance from a business or entrepreneurship advisor.

Geben Sie Beispiele (Few-Shot-Prompting)

Indem Sie einige Beispiele für Ihre Aufgabe in die Aufforderung aufnehmen, können Sie eine strukturierte Vorlage für Amazon Nova 2 erstellen, der Sie folgen können. Dies verringert Unklarheiten und verbessert die Genauigkeit und Qualität der Ausgabe. Die Technik, klare Beispiele zu liefern, um die Antworten des Modells besser auf das gewünschte Ergebnis abzustimmen, wird als Few-Shot-Prompting bezeichnet.

Das Konzept des Few-Shot-Promptings besteht darin, dem Sprachmodell einige Beispiele für die Aufgabe sowie das Eingabe- und Ausgabeformat zur Verfügung zu stellen und es dann aufzufordern, auf der Grundlage der bereitgestellten Beispiele die Ausgabe für eine neue Eingabe zu generieren. Diese Methode hilft auch bei der Klärung komplexer Anweisungen oder Aufgaben, sodass Amazon Nova 2 leichter verstehen und interpretieren kann, was gefragt wird.

So hilft das Hinzufügen von Beispielen zum Prompt:

Das Hinzufügen von Beispielen kann dem Modell bei der Produktion helfen

- Konsistente Antworten, die dem Stil der Beispiele entsprechen
- Leistungsstarke Antworten durch geringere Wahrscheinlichkeit von Fehlinterpretationen von Anweisungen und einer Minimierung von Halluzinationen

Der Umfang, in dem sich die Modellleistung durch Few-Shot-Prompting verbessert, hängt von der Qualität und Vielfalt der ausgewählten Beispiele ab. Die folgenden Punkte veranschaulichen die Merkmale guter Einstellungen im Prompt:

- Wählen Sie verschiedene Beispiele aus: Die ausgewählten Beispiele sollten die Verteilung Ihrer Erwartungen input/output in Bezug auf die Vielfalt (von häufigen Anwendungsfällen bis hin zu Randfällen) widerspiegeln, um relevante Anwendungsfälle angemessen abzudecken. Es ist wichtig, jegliche Verzerrungen in Ihren Beispielen zu vermeiden, da Verzerrungen in den Eingaben dazu führen können, dass auch die Ausgaben verzerrt sind.

- Komplexitätsstufen abgleichen: Die Komplexität der bereitgestellten Beispiele sollte mit der Zielaufgabe oder dem Zielszenario übereinstimmen. Es ist wichtig, sicherzustellen, dass der Komplexitätsgrad zwischen der erwarteten Eingabe und dem ausgewählten Beispiel im Prompt übereinstimmt.
- Auf Relevanz achten: Die ausgewählten Beispiele sollten in direktem Zusammenhang mit dem vorliegenden Problem oder Ziel stehen. Dadurch wird die Kohärenz und Einheitlichkeit der Antworten gewährleistet.

 Tip

Sollten die oben genannten Vorschläge nicht zum Erfolg führen, empfehlen wir Ihnen, ein RAG-basiertes System zu entwickeln, das den Prompt durch eine dynamische Auswahl von Aufnahmen ergänzt, die auf den Ähnlichkeiten zwischen der vom Benutzer eingegebenen Suchanfrage und einem verfügbaren Pool von Aufnahmen basiert.

Beispiel 1: Beispiele im Benutzer-Prompt angeben

Hier versucht Ihr Benutzer, eingehende Kundensupporttickets in vordefinierte Kategorien zu klassifizieren. Sie können Amazon Nova 2-Modellen einige Beispiele für korrekt klassifizierte Tickets zur Verfügung stellen, um das Verständnis der Kategorien und der in den Tickets verwendeten Sprache zu verbessern. Die Beispiele sollten präzise sein und alle Aufgaben abdecken, die in Ihrer Anwendung behandelt werden. Wenn es einen bestimmten Feldnamen gibt, der für die Aufgaben von Bedeutung ist, wie Ticket oder Category in diesem Beispiel, kann Ihr Benutzer diese Felder direkt gefolgt von einem Doppelpunkt ":" verwenden.

0-shot prompt

Nutzer:

```
Please classify the following customer support tickets into one of the categories:  
"Technical Issue," "Billing Inquiry," or "General Inquiry."
```

```
Ticket: "Can you explain why my latest bill is higher than usual? I haven't changed  
my plan."
```

Assistentin:

```
The customer support ticket should be classified as a "Billing Inquiry."
```

Here's the reasoning:

- The customer is asking about the reason for a change in their latest bill amount.
- The context revolves around billing and payment, which falls under the category of "Billing Inquiry."

3-shot prompt

Nutzer:

Please classify the following customer support tickets into one of the categories: "Technical Issue," "Billing Inquiry," or "General Inquiry."

Use these examples to guide your classification:

Ticket: "I can't log in to my account. The system keeps giving me an error message."

Category: Technical Issue

Ticket: "I received an email saying my account will be suspended unless I make a payment. Is this a scam?"

Category: Billing Inquiry

Ticket: "What are the hours of operation for your customer support team?"

Category: General Inquiry

Now, classify the following ticket:

Ticket: "Can you explain why my latest bill is higher than usual? I haven't changed my plan."

Assistentin:

Category: Billing Inquiry

Explanation: The ticket is asking for an explanation regarding a change in the billing amount, which falls under the billing category as it pertains to questions about charges or payments.

Beispiel 2: Bereitstellung von Beispielen als Runden-Prompts

In diesem Fall sind die Beispiele als Runden dargestellt, eine Runde pro Beispiel, wobei die Rolle User die Eingabe und die Rolle Assistant die erwartete Ausgabe für dieses Beispiel enthält.

0-shot Prompt

System:

Your task is to Classify the following texts into the appropriate categories. The categories to classify are:

Categories:

- Food
- Entertainment
- Health
- Wealth
- Other

Nutzer:

I have 20\$ in my pocket.

Assistentin:

Category: Wealth

Explanation: The text mentions a specific amount of money, which falls under the category of wealth. The presence of a monetary value directly relates to financial status or economic aspect.

3-shot Prompt (as turns)

System:

Your task is to Classify the following texts into the appropriate categories. The categories to classify are:

Categories:

- Food
- Entertainment
- Health
- Wealth
- Other

Nutzer:

I love to eat pizza.

Assistentin:

Food

Nutzer:

I enjoy watching movies.

Assistentin:

Entertainment

Nutzer:

I am going to the gym after this.

Assistentin:

Health

Nutzer:

I have 20\$ in my pocket.

Assistentin:

Wealth

Beispiel 3: Bereitstellung von Beispielen im System-Prompt

In diesem Beispiel können Sie einen Abschnitt „Beispiel“ festlegen und anschließend eine Reihe von Beispielen innerhalb des System-Prompts auflisten. Diese Methode, Beispiele im Prompt bereitzustellen, ist besonders nützlich, wenn Ihre Beispiele lang und komplex sind, und unterstützt das Modell dabei, Beispielaufnahmen zu finden.

0-shot Prompt

System:

You are an AI assistant helping to draft professional reports for enterprise stakeholders. Ensure the report is formatted in rich text, with headings, bullet points, and highlighted important tasks.

Nutzer:

Draft a detailed project update report for our stakeholders, summarizing the project milestones achieved, tasks completed, and future plans.

Assistentin:

Project Update Report

Executive Summary

This report provides a comprehensive update on the project milestones achieved, tasks completed, and future plans. Our team has made significant progress, and we are on track to meet the project goals. The following sections outline the details of our accomplishments and upcoming activities.

Project Milestones Achieved

1. Project Initiation

- **Milestone Date:** July 15, 2023
- **Description:** Completed initial project planning and secured stakeholder approval.

2. System Design Completion

- **Milestone Date:** September 30, 2023
- **Description:** Finished the detailed system design and received positive feedback from technical review meetings.

3. Prototype Development

- **Milestone Date:** November 15, 2023
- **Description:** Developed and tested a working prototype of the system.

Tasks Completed

1. Requirement Gathering

- **Description:** Conducted comprehensive stakeholder interviews and collected detailed requirements.
- **Highlighted Important Tasks:**
 - **User Story Mapping:** Mapped out user stories to ensure all user needs are addressed.
 - **Requirement Documentation:** Created detailed requirement specifications.

**2. System Architecture Design

- **Description:** Designed the system architecture, focusing on scalability and maintainability.
- **Highlighted Important Tasks:**
 - **Technology Stack Selection:** Chose the appropriate technology stack based on project requirements.
 - **Architecture Diagrams:** Developed detailed architecture diagrams for easy understanding.

**3. Prototype Development and Testing

- **Description:** Developed and rigorously tested the prototype.
- **Highlighted Important Tasks:**
 - **Coding:** Implemented core functionalities of the prototype.
 - **Testing:** Conducted unit and integration testing to ensure prototype reliability.

Future Plans

**1. Full System Development

- **Description:** Begin the full-scale development of the system based on the approved design and prototype.
- **Highlighted Important Tasks:**
 - **Module Development:** Develop each module as per the design specifications.
 - **Code Reviews:** Implement regular code reviews to maintain code quality.

**2. User Acceptance Testing (UAT)

- **Description:** Conduct UAT to ensure the system meets user requirements and is ready for deployment.
- **Highlighted Important Tasks:**
 - **Test Plan Development:** Create detailed UAT plans and test cases.
 - **UAT Execution:** Execute UAT and gather feedback for final adjustments.

```

### **3. Deployment and Training**
- **Description:** Deploy the system and provide necessary training to end-users.
- **Highlighted Important Tasks:**
  - **Deployment:** Roll out the system to the production environment.
  - **Training Sessions:** Organize training sessions for users to familiarize them
    with the new system.

---

## Conclusion
Our project has successfully achieved key milestones and completed significant
tasks. With the current momentum, we are well-positioned to meet our future
objectives. We remain committed to delivering a high-quality system that meets all
stakeholder expectations.

---

**Prepared by:**
[Your Name]
[Your Position]
[Date]

**Contact Information:**
[Your Email]
[Your Phone Number]

---

This detailed update aims to keep stakeholders informed and reassured about the
project's progress and future direction. For any queries or further information,
please do not hesitate to contact me directly.

```

2-shot Prompt

System:

```

You are an AI assistant helping to draft professional reports for enterprise
stakeholders. Below are a few examples of well-formatted project update reports to
guide your response.

<Example 1>

<b>Project Update Report</b><br>
<i>Date:</i> January 15, 2023<br>

```

Project Milestones Achieved:

- Successfully launched the new CRM system.
- Integrated the marketing automation tool.
- Completed the employee training sessions.

Tasks Completed:

- Developed the user manual.
- Conducted system testing.
- Prepared the training materials.

Future Plans:

- Roll out the CRM system to all departments.
- Schedule follow-up training sessions.
- Monitor system performance and make necessary adjustments.

Prepared by:

[Your Name]

[Your Position]

[Your Contact Information]

<Example 2>

Project Update Report

Date: February 20, 2023

Project Milestones Achieved:

- Launched the new website.
- Completed the SEO optimization.
- Organized the stakeholder meeting.

Tasks Completed:

- Designed the website layout.
- Wrote the content for the website.
- Tested the website functionality

Future Plans:

- Implement the analytics tracking.
- Launch the social media campaign.
- Gather feedback from stakeholders.

```
<hr>
<b>Prepared by:</b><br>
[Your Name]<br>
[Your Position]<br>
[Your Contact Information]
```

Nutzer:

Draft a detailed project update report for our stakeholders, summarizing the project milestones achieved, tasks completed, and future plans.

Assistentin:

```
<b>Project Update Report</b><br>
<i>Date:</i> October 5, 2023<br>
<hr>

<b>Project Milestones Achieved:</b><br>
- Successfully completed the implementation of the new enterprise resource planning (ERP) system.<br>
- Conducted and completed the first phase of the data migration process.<br>
- Successfully launched the new inventory management module.

<b>Tasks Completed:</b><br>
- Developed and finalized the comprehensive user training program, including detailed user manuals and video tutorials.<br>
- Conducted extensive system integration testing with all existing systems and ensured seamless interoperability.<br>
- Executed the initial data migration from the legacy system to the new ERP system, resulting in a 95% accuracy rate.

<b>Future Plans:</b><br>
- Roll out the new ERP system to all departments in the next two phases.<br>
- Schedule and conduct follow-up training sessions for all employees.<br>
- Implement the remaining modules of the ERP system, including financial management and human resources.<br>
- Establish a robust monitoring and support framework to ensure smooth system operation and address any issues promptly.

<hr>
<b>Prepared by:</b><br>
[Your Name]<br>
```

```
[Your Position]<br>
[Your Contact Information]
```

```
---
```

This detailed report provides a clear and concise overview of the project's progress, highlighting the milestones achieved, tasks completed, and future plans. It ensures stakeholders are well-informed and can make strategic decisions based on the current status of the project.

Systeme zum Aufrufen von Tools

Der Toolaufruf ist für Amazon-Nova-Modelle verfügbar, indem Sie in Ihrer Anfrage ein Tool-Konfigurationsschema übergeben. Der Prompt für das Modell wird durch diese Tool-Konfiguration erweitert, sodass es sich hier um einen äußerst effektiven Ausgangspunkt für die Optimierung Ihres Tool-Aufrufsystems handelt.

Beachten Sie die folgenden Schlüsselprinzipien:

- Die Definitionen der Tools sollten klar und präzise sein. Sie sollte leicht zu verstehen sein und die Absicht muss deutlich erkennbar sein.
- Definieren Sie anhand der wichtigsten Unterscheidungsmerkmale und Randbedingungen, wann ein Tool einem anderen vorzuziehen ist.
- Seien Sie kritisch bei den Typen der Eingabeargumente. Fragen Sie, sind sie sinnvoll und würde man erwarten, dass sie normalerweise auf diese Weise verwendet werden?

Verwenden Sie „Tool-Auswahl“, um zu steuern, wann ein Tool aufgerufen wird

Mit dem Tool-Auswahlparameter können Sie das Verhalten beim Tool-Aufruf anhand des Modells anpassen. Wir empfehlen, diesen Wert zu verwenden, um präzise steuern zu können, welche Tools wann aufgerufen werden.

Für Anwendungsfälle wie strukturierte Ausgaben kann es beispielsweise erforderlich sein, dass bei jedem Aufruf von Amazon Nova ein bestimmtes Tool aufgerufen wird. Sie können das Schema Ihrer Ausgabe als das Tool definieren und dann die Tool-Auswahl auf den Namen dieses Tools festlegen.

```
{
  "toolChoice": {
```



```
    "tool": {
      "name": "name_of_tool"
    }
  }
}
```

Für viele agentenbasierte Anwendungsfälle möchten Sie möglicherweise sicherstellen, dass das Modell immer eines der verfügbaren Tools auswählt. Dazu können Sie die Tool-Auswahl auf any festlegen, wodurch bei jedem Aufruf des Modells genau ein Tool aufgerufen wird.

```
{
  "toolChoice": {
    "any": {}
  }
}
```

Schließlich können Sie für Anwendungsfälle, in denen es stark vom Kontext der Konversation abhängt, ob ein Tool aufgerufen wird, die Tool-Auswahl auf auto einstellen. Dies ist das Standardverhalten und überlässt die Tool-Auswahl vollständig dem Modell.

```
{
  "toolChoice": {
    "auto": {}
  }
}
```

Fortgeschrittene Aufforderungstechniken

In diesen Abschnitten finden Sie erweiterte Anleitungen, wie Sie die Qualität Ihrer Eingabeaufforderungen verbessern und wichtige Funktionen wie erweitertes Denken nutzen können.

Verwenden Sie den Argumentationsmodus

Amazon Nova 2-Modelle bieten einen optionalen Argumentationsmodus, der den Ansatz des Modells zur Lösung komplexer Probleme verbessert, indem es Probleme systematisch durcharbeiten kann, bevor es reagiert. Die Nutzung des Argumentationsmodus des Modells ist eine leistungsstarke Methode, um die Genauigkeit Ihrer Eingabeaufforderungen zu verbessern.

Verwendungszweck: Der Argumentationsmodus wird für komplexe Aufgaben empfohlen, z. B. für folgende Anwendungsfälle:

- Mehrere Argumentationsschritte: Mathematische Beweise, Algorithmusdesign, Systemarchitektur
- Querverweise: Dokumentenanalyse, Vergleich von Optionen, Bewertung von Kompromissen
- Fehleranfällige Berechnungen: Finanzmodellierung, Datenanalyse, komplexes Debugging
- Planung mit Einschränkungen: Ressourcenoptimierung, Abhängigkeitsmanagement, Risikobewertung
- Komplexe Klassifizierungen: Kategorisierung mit mehreren Bezeichnungen, hierarchische Taxonomien, nuancierte Entscheidungsgrenzen
- Szenarien zum Aufrufen von Tools: Mehrstufige API-Workflows, Optimierung von Datenbankabfragen, koordinierte Systemintegrationen

 Note

Weitere Informationen zum Argumentationsmodus finden Sie unter. [Argumentation verwenden](#)

Gehen Sie von oben nach unten vor

In Situationen, in denen das Modell mehrere Lösungsansätze bewerten muss, weisen Sie es an, einen Top-down-Ansatz zu wählen.

- Amazon Nova 2-Modelle schneiden besser ab, wenn das Modell mit dem Gesamtbild beginnt und es dann in kleinere, detailliertere Teilprobleme oder Schritte unterteilt.
- Weisen Sie das Modell explizit an, zuerst das Hauptziel zu identifizieren und es dann in überschaubare Komponenten zu zerlegen, bevor Sie die Details der einzelnen Teile durcharbeiten.
- Dieser strukturierte Ansatz hilft dem Modell, sein Denken zu organisieren und kohärentere Argumentationsketten zu entwickeln.

Beispiel:

```
{{User query}}. Start with the big picture and break it down into progressively smaller, more detailed subproblems or steps.
```

Steuere die Gedankenkette

Der Argumentationsmodus bietet zwar eine höhere Genauigkeit durch systematische Problemlösung, es gibt jedoch bestimmte Szenarien, in denen die Chain-of-Thought-Aufforderung (CoT) im Modus ohne Argumentation Ihren Bedürfnissen besser gerecht werden kann.

Wann sollte er verwendet werden:

- **Transparenz und Überprüfbarkeit:** Wenn Sie den Argumentationsprozess des Modells einsehen, verifizieren oder prüfen möchten, bietet CoT einen vollständigen Überblick über jeden Schritt. Dies ist entscheidend für regulierte Branchen, wichtige Entscheidungen oder wenn Sie die Logik hinter einer Antwort dokumentieren möchten.
- **Benutzerdefinierte Argumentationsstrukturen:** Verwenden Sie CoT, um bestimmte Argumentationsmuster oder -methoden durchzusetzen. Sie können das Modell so ausrichten, dass es den Entscheidungsrahmen Ihrer Organisation folgt, domänenspezifische Problemlösungsansätze verwendet oder sicherstellt, dass Faktoren in einer bestimmten Reihenfolge berücksichtigt werden.
- **Schnelle Entwicklung und Debugging:** Während der Phase der schnellen Entwicklung hilft Ihnen CoT dabei, zu verstehen, wie das Modell Probleme angeht, zu erkennen, wo die Argumentation versagt, und Ihre Eingabeaufforderungen effektiver zu bearbeiten.
- **Hybride Ansätze:** Erwägen Sie, während der Entwicklung CoT zu verwenden, um Ihre Eingabeaufforderungen zu perfektionieren, und wechseln Sie dann für den produktiven Einsatz in den Argumentationsmodus, sobald Sie sich mit der Herangehensweise des Modells an Ihren spezifischen Anwendungsfall sicher sind.

Note

Nicht für alle Aufgaben ist CoT erforderlich. Lassen Sie das Modell bei einfacheren Aufgaben seinen eigenen Argumentationsprozess verwenden.

Richtschnur für die CoT-Ausrichtung des Modells:

```
{{User query}} Please follow these steps:
```

1. `{{Step 1}}`
2. `{{Step 2}}`

...

Verwendung langer Kontextfenster

Amazon Nova 2-Modelle haben eine unterstützte Kontextlänge von 1 Million Token und zeichnen sich durch das Verständnis von Code und die Beantwortung von Fragen bei langen Dokumenten aus. Die Leistung (einschließlich der Einhaltung der Systemaufforderung und der Verwendung von Tools) kann mit zunehmender Kontextgröße leicht abnehmen.

Wie benutzt man es:

- Platzieren Sie umfangreiche Daten am Anfang: Positionieren Sie Ihre umfangreichen Dokumente und Eingaben möglichst am Anfang Ihres Prompts. Platzieren Sie sie vor Ihrer Anfrage, Ihren Anweisungen und Beispielen.
- Platzieren Sie Anweisungen am Ende: Positionieren Sie Ihre Anweisungen am Ende des Prompts. Das Modell erzielt die besten Ergebnisse, wenn zunächst der Kontext und anschließend die Anweisungen bereitgestellt werden.
- Strukturieren Sie Start- und Endmarkierungen für den Dokumentinhalt: Verwenden Sie Start- und Endmarkierungen wie `DOCUMENT {idx} START` und `DOCUMENT {idx} END`, um den Anfang und das Ende langer Dokumente zu kennzeichnen, wobei `{idx}` für den Index des jeweiligen Dokuments steht.

Beispielvorlage:

```
// Provide your long inputs at the top of your prompt
BEGIN INPUT DOCUMENTS

DOCUMENT 1 START
{{Your document}}
DOCUMENT 1 END

END INPUT DOCUMENTS

// Then specify your query and instructions
BEGIN QUESTION
{{User query}}
END QUESTION

BEGIN INSTRUCTIONS
{{Instructions}}
```

END INSTRUCTIONS

Grundlegende Antworten im unterstützenden Text

Wir empfehlen, dass Sie dem Modell vertrauenswürdige Informationen zur Verfügung stellen, die für die Eingabeabfrage relevant sind. Diese Informationen sind zusammen mit der Eingabeabfrage häufig Teil eines Systems, das als Retrieval Augmented Generation (RAG) bezeichnet wird.

- Bei diesem Prozess werden einige relevante, kontextbezogene Dokumente oder Informationen um die eigentliche Benutzeraufforderung erweitert, sodass das Modell vertrauenswürdige Inhalte erhält, um eine relevante und genaue Antwort zu generieren.
- Wenn Amazon Nova 2 angewiesen wird, anhand eines Referenztextes aus einer vertrauenswürdigen Quelle zu antworten, kann das Unternehmen seine Antwort auf der Grundlage des bereitgestellten Materials verfassen und sicherstellen, dass seine Antwort auf genauen und relevanten Informationen basiert, wodurch die Zuverlässigkeit und Glaubwürdigkeit der generierten Inhalte erhöht wird.
- Die Verwendung eines Referenztextes kann dazu beitragen, Halluzinationen zu vermeiden und dadurch die Gesamtqualität und Vertrauenswürdigkeit der Antworten zu verbessern. Um Halluzinationen zu minimieren, empfehlen wir, **DO NOT USE INFORMATION THAT IS NOT IN REFERENCE TEXTS!** in Ihrer Modellanleitung ausdrücklich zu erwähnen.

Prompt-Vorlage

System:

In this session, the model has access to search results and a user's question, your job is to answer the user's question using only information from the search results.

Model Instructions:

- DO NOT USE INFORMATION THAT IS NOT IN SEARCH RESULTS!

User: {Query}

Resource: Search Results: {Reference texts}

Beispiel: Durch die Bereitstellung von Hintergrundkontexten kann verhindert werden, dass das Modell halluziniert

Dieses Beispiel zeigt, wie der Grundkontext verhindern kann, dass das Modell halluziniert.

System:

In this session, the model has access to search results and a user's question, your job is to answer the user's question using only information from the search results. Model Instructions:- DO NOT USE INFORMATION THAT IS NOT IN SEARCH RESULTS!

Nutzer:

What were the economic impacts of the COVID-19 pandemic on the United States in 2020?

Resource: Search Results: In 2020, the United States experienced significant economic impacts due to the COVID-19 pandemic. The U.S. economy contracted by 3.5% in 2020, according to the Bureau of Economic Analysis. Unemployment rates surged to 14.7% in April 2020, the highest since the Great Depression, before gradually declining. Small businesses faced severe challenges, with millions of firms closing permanently. Additionally, consumer spending dropped sharply as people reduced non-essential expenditures and saved more. Government intervention played a critical role in mitigating these impacts through stimulus packages and support programs, such as the Paycheck Protection Program (PPP) for small businesses and direct payments to individuals. Despite these measures, the economic recovery remained uneven across different sectors and regions.

Boden mit Zitationsmarkern

Für umfangreiche Dokumentaufgaben empfehlen wir, dass Sie das Amazon Nova 2-Modell anweisen, seine Antworten anhand von Zitaten aus den entsprechenden Abschnitten der Dokumente zu begründen, bevor es mit der Aufgabe fortfährt.

Dieser Ansatz unterstützt das Modell dabei, sich auf die relevantesten Informationen zu konzentrieren und Ablenkungen durch irrelevante Inhalte zu vermeiden. Wenn Sie beantragen, dass das Modell seine Antwort begründet, sollten die Abschnitte, die zitiert werden können, nummeriert werden. Zum Beispiel Passage %[1]%, Passage %[2]% und so weiter.

Beispiele: Verwendung von Zitationsmarkierungen

Example Aufforderung zur Eingabe von Zitationsmarken

You are an AI financial assistant. Your task is to find patterns and insights from multi-year financial documents

Passage %[1]%
{{Your document}}

```

Passage %[2]%
{{Your document}}

## Task:
Analyze my LLC's reports across multiple years to identify significant performance
trends, segment growth patterns and strategic shifts.

## Context information:
- You have access to my LLC's annual financial reports (10-K) for multiple fiscal years
  in PDF format
- These reports contain comprehensive financial data including income statements,
  balance sheets, cash flow statements and management discussions
- The analysis should focus on year-over-year comparisons to identify meaningful trends
- I operate two business segments, one in Massachusetts and one in New York

Based on the provided Context, extract key financial metrics from each year's reports
phrases from the documents.
Place citations as inline markers (e.g., %[1]%, %[2]%, etc.) directly within the
relevant parts of the response
text. Do not include a separate citation section after the response.
## Response Schema:
%% (Extracted Financial Metrics)
%% (Extracted Financial Metrics)
%% (Extracted Financial Metrics)
...

```

Nachdem Sie die wichtigsten Informationen auf der Grundlage der Aufgabe des Benutzers extrahiert haben, können Sie die extrahierten Finanzkennzahlen verwenden, um die relevanten Fragen wie folgt zu beantworten:

Example Folgeanalyse mit extrahierten Kennzahlen

```

## Task
Analyze my LLC's financial reports across multiple years to identify significant
performance trends, segment growth patterns and strategic shifts.

{{extracted financial metrics}}

## Model Instructions:
- Organize data chronologically to identify meaningful trends
- DO compare segment performance across the five-year period
- DO identify significant strategic shifts or investments mentioned in management
  discussions

```

- DO NOT make speculative predictions beyond what is supported by the data
- ALWAYS note any changes in accounting practices or reporting methodologies that might affect year-over-year comparisons

Response style and format requirements:

- Respond in markdown
- Structure the analysis with clear headings and subheadings
- Present key financial metrics in tabular format showing all five years side-by-side
- Include percentage changes year-over-year for all major metrics
- Create a section dedicated to visualizing the most significant trends (with descriptions of what would be shown in charts)
- Limit the executive summary to 250 words maximum
- Format segment analysis as separate sections with consistent metrics across all segments
- MUST include a Key Insights bullet-pointed list at the end of each major section

Verwenden Sie Nova Web Grounding

Anstatt direkt nach Zitaten zu fragen, um das Modell im unterstützenden Text zu untermauern, bieten Amazon Nova 2-Modelle ein internes Web-Grounding-Tool, das verwendet werden kann. Wenn diese Option aktiviert ist, fragen Amazon Nova 2-Modelle direkt das Internet und die Wissensdiagramme von Amazon ab und untermauern die endgültige Antwort mit Zitaten.

Weitere Informationen zur Nutzung von Amazon Nova Web Grounding finden Sie im [Amazon Nova Web Grounding-Benutzerhandbuch](#).

Produzieren Sie strukturierte Ergebnisse

Um konsistente und strukturierte Ausgabeformate zu gewährleisten, können Sie strukturierte Ausgaben verwenden, darunter Formate wie XML, JSON, Markdown, oder Funktionen zur Verwendung von Tools verwenden.

- Dieser Ansatz ermöglicht es nachgeschalteten Systemen, die vom Modell generierten Ausgaben effektiver zu verstehen und zu analysieren.
- Durch die Bereitstellung expliziter Anweisungen für das Modell werden die Antworten auf eine Weise generiert, die einem vordefinierten Schema entspricht.

Wenn der Downstream-Parser beispielsweise bestimmte Namenskonventionen für Schlüssel in einem JSON-Objekt erwartet, sollten Sie das Antwortschema am Ende der Aufforderung angeben. Wenn Sie es vorziehen, Antworten im JSON-Format ohne Präambeltext zu erhalten, weisen Sie

das Modell außerdem entsprechend an. Geben Sie also ausdrücklich an, dass Sie nur die JSON-Ausgabe generieren möchten. Geben Sie KEINE Präambel an, um eine saubere Ausgabe zu gewährleisten.

Tip

- Wir achten darauf, dass die Anforderungen an das Datenformat am besten eingehalten werden, wenn sie im Schema selbst definiert werden, und nicht anhand von Beispielen (z. B. Angabe von Datumsangaben im YYYY/MM/DD Format).
- Für einfache JSON-Ausgaben mit bis zu 10 Schlüsseln finden Sie das Schema unten. Für komplexere Schemas empfehlen wir Ihnen, Ihr Schema mit einem Tool zu definieren. Bei der Verwendung des Tools wird eine Technik verwendet, die als eingeschränkte Dekodierung bezeichnet wird und die Konformität des Modells für diese komplexen Schemas erhöht.

Gängige Formatierungsschemas

Im Folgenden finden Sie Beispiele für gängige Formatierungsschemas.

JSON

```
JSON_format = ""Write your response following the JSON format below:
```

```
```json
{
 "key1": "value1",
 "key2": "value2",
 key3: [{
 "key3_1": "value_3_1 written in YYYY/MM/DD format",
 "key3_2": "value_3_2 day of the week written in full form",
 ...}]
}```
""
```

### XML

```
XML_format = ""Write your response following the XML format below:
```

```
<output>
 <task>"task1"</task>
```

```

 <subtask>
 <task1_result> (task 1 result)</task1_result>
 <task2_result> (task 2 result)</task2_result>
 <task3_result> (task 3 result)</task3_result>
 </subtask>
 <task>"task2"</task>
 <subtask>
 <task1_result> (task 1 result)</task1_result>
 <task2_result> (task 2 result)</task2_result>
 <task3_result> (task 3 result)</task3_result>
 </subtask>
</output>

"""

```

## Markdown

```

markdown_schema = """Write your response following the markdown format below:

Introduction
(2-3 line intro)

Design Guidance
(Bulleted list of design guidance)

Step by Step Instructions on Execution
(Bulleted list of instructions with each with bold title.

Conclusion
(conclusion)

"""

```

## Inhalt des Assistenten vorab ausfüllen

Wenn Sie strukturierte Ausgaben ohne Argumentation erstellen, können Sie die Reaktion des Modells beeinflussen, indem Sie den Inhalt des Assistenten vorab ausfüllen.

Das Vorfüllen verbessert die Konsistenz des Ausgabeformats im Modus ohne Argumentation. Es ermöglicht Ihnen, die Aktionen des Modells zu steuern, Präambeln zu umgehen und bestimmte

Ausgabeformate wie JSON und XML durchzusetzen. Wenn Sie beispielsweise den Assistenteninhalt mit { oder vorfüllen ```json, leitet diese Eingabe das Modell dazu, das JSON-Objekt ohne zusätzliche Informationen zu generieren.

#### Tip

Wenn Sie explizit nach dem Extrahieren von JSON suchen, besteht ein gängiges Muster darin, eine Stoppssequenz vorzufüllen ```json und eine Stoppssequenz hinzuzufügen. ``` Dadurch wird sichergestellt, dass das Modell ein JSON-Objekt ausgibt, das programmgesteuert analysiert werden kann.

### Example Inhalt des Assistenten vorab ausfüllen

Der folgende Code veranschaulicht, wie man mit der API vorab ausfüllt:

```
import boto3
import json

Create a Bedrock Runtime client.
client = boto3.client(
 "bedrock-runtime",
 region_name="us-east-1"
)

request_body = {
 "system": [
 {"text": "You write JSON objects based on the given instructions"}
],
 "messages": [
 {
 "role": "user",
 "content": [{"text": "Provide details about the best selling full-frame cameras in past three years. Answer in JSON format with keys like name, brand, price and a summary."}]
 },
 {
 "role": "assistant",
 "content": [{"text": " Here is the JSON response: ```json"}]
 }
],
 "inferenceConfig": {
```

```
 "maxTokens": 1000,
 }
}

Invoke the model and extract the response body.
response = client.invoke_model(
 modelId="amazon.nova-2-lite-v1:0",
 body=json.dumps(request_body)
)

model_response = json.loads(response["body"].read())
```

Geben Sie ein Tool an, das für komplexe Schemas verwendet werden soll

Ein anderer Ansatz besteht darin, Tools zu verwenden, um ein bestimmtes Schema für die Antwort des Modells zu erzwingen, indem das pydantische JSON-Schema in den Abschnitt „Schema zur Verwendung des Tools“ aufgenommen wird. Sie können die Tool-Auswahl anhand des bereitgestellten Schemas angeben und die Antwort von Amazon Nova wird auf der Grundlage des ausgewählten Tools strukturiert. Weitere Informationen darüber, wie Sie den Einsatz von Tools optimal nutzen können, finden Sie unter Verwendung von [Tools](#).

## Beispiele

### Beispiel 1: Ein Ausgabeschema hinzufügen

Durch Hinzufügen des Abschnitts „Ausgabeschema“ mit dem entsprechenden Schema wird das Modell dazu veranlasst, dieses Schema vorrangig anzupassen. Die Modellausgabe ist jedoch nicht deterministisch und kann vom Ausgabeschema abweichen.

### Unspecific Prompt

Benutzer:

```
Provide details about the best selling full-frame cameras in past three years.
Answer in JSON format with keys like name, brand, price and a summary.
```

Assistentin:

```
```json
[
{
```

```

"name": "Sony Alpha A7R IV",
"brand": "Sony",
"price": "Approximately $3,500",
"summary": "The Sony Alpha A7R IV is renowned for its exceptional image quality, thanks to a 61-megapixel full-frame sensor. It also features 4K video recording and a robust build, making it a favorite among professional photographers and videographers."
},
{
"name": "Canon EOS R5",
"brand": "Canon",
"price": "Approximately $3,900",
"summary": "The Canon EOS R5 combines high-resolution imaging with advanced video capabilities. It houses a 45-megapixel sensor, 8K video recording, and impressive autofocus performance, appealing to both photography and filmmaking professionals."
},
{
"name": "Nikon Z7 II",
"brand": "Nikon",
"price": "Approximately $2,800",
"summary": "The Nikon Z7 II offers a 45.7-megapixel full-frame sensor and is praised for its high resolution and excellent dynamic range. It also supports 4K video recording and features a versatile Z-mount lens system, making it a strong contender in the full-frame market."
},
{
"name": "Fujifilm GFX 100S",
"brand": "Fujifilm",
"price": "Approximately $7,000",
"summary": "While not a traditional full-frame camera, the Fujifilm GFX 100S stands out with its 102-megapixel medium format sensor. It is lauded for its stunning detail and color reproduction, though it comes at a higher price point and is aimed at specialized users."
}
]
...

```

Specific Prompt

Nutzer:

Provide details about the best selling full-frame cameras in past three years. You MUST answer in JSON format only. Write your response following the the format below:

```
[{
  "name": "name goes here",
  "brand": "brand goes here",
  "price": "price goes here",
  "summary": "summary goes here"
}]
```

Assistentin:

```
[
  {
    "name": "Nikon D850",
    "brand": "Nikon",
    "price": "$3,296.95",
    "summary": "The Nikon D850 is a professional full-frame DSLR camera known for its exceptional image quality, 45.7-megapixel resolution, 7 fps continuous shooting, and 4K video capabilities."
  },
  {
    "name": "Canon EOS 5D Mark IV",
    "brand": "Canon",
    "price": "$3,499.00",
    "summary": "The Canon EOS 5D Mark IV is a popular full-frame DSLR appreciated for its 30.4-megapixel sensor, 4K video recording, robust build quality, and reliable autofocus system."
  },
  {
    "name": "Sony A7R III",
    "brand": "Sony",
    "price": "$3,198.00",
    "summary": "The Sony A7R III is a high-resolution full-frame mirrorless camera renowned for its 42.4-megapixel sensor, excellent low-light performance, and versatile lens compatibility."
  },
  {
    "name": "Fujifilm GFX 100S",
    "brand": "Fujifilm",
    "price": "$5,999.99",
    "summary": "The Fujifilm GFX 100S is a medium format mirrorless camera that stands out for its 102-megapixel sensor, high dynamic range, and exceptional color reproduction."
  },
  {

```

```
"name": "Sony A7 III",
"brand": "Sony",
"price": "$1,998.00",
"summary": "The Sony A7 III is a full-frame mirrorless camera popular among
enthusiasts and professionals for its 24.2-megapixel sensor, fast autofocus, and 4K
video capabilities."
}
]
```

Beispiel 2: Die Modellantwort vorab ausfüllen

Ein weiterer Ansatz besteht darin, die Antwort des Modells vorzufüllen, indem der gewünschte Anfangstext in die Nachricht des Assistenten aufgenommen wird. In diesem Fall wird die Antwort des Amazon-Nova-Modells dort fortgesetzt, wo die Nachricht des Assistenten aufhört.

Tipp: Das Vorfüllen ist nur gültig, wenn die Argumentation nicht aktiviert ist.

Benutzer:

```
Provide details about the best selling full-frame cameras in past three years.
Your response should be in JSON format, with the following keys: name, brand, year,
price, summary.
```

Assistent (Vorfüllen):

```
```json
```

Assistentin:

```
{
 "cameras": [
 {
 "name": "Sony Alpha A7 III",
 "brand": "Sony",
 "year": 2018,
 "price": "$1999",
 "summary": "The Sony Alpha A7 III is a highly acclaimed full-frame mirrorless camera
known for its excellent image quality, advanced autofocus system, and 4K video
capabilities."
 },
 {
 "name": "Canon EOS R5",
```

```
"brand": "Canon",
"year": 2020,
"price": "$3899",
"summary": "The Canon EOS R5 is a top-tier full-frame mirrorless camera that offers
stunning 45MP images, 8K video recording, and exceptional performance in various
lighting conditions."
},
{
"name": "Nikon Z7 II",
"brand": "Nikon",
"year": 2020,
"price": "$2999",
"summary": "The Nikon Z7 II is a flagship full-frame mirrorless camera with a 45.7MP
sensor, superb image quality, and advanced video recording features."
},
{
"name": "Fujifilm GFX 100S",
"brand": "Fujifilm",
"year": 2020,
"price": "$7999",
"summary": "The Fujifilm GFX 100S is a medium format mirrorless camera known for its
impressive 102MP sensor, beautiful film simulations, and versatile lens options."
},
{
"name": "Sony Alpha A7R IV",
"brand": "Sony",
"year": 2019,
"price": "$3499",
"summary": "The Sony Alpha A7R IV features a 61MP sensor, excellent low-light
performance, and advanced video capabilities, making it a favorite among professional
photographers."
}
]
}
```

### Beispiel 3: Ein zu verwendendes Tool festlegen

Als Alternative zur Verwendung der Prefill-Technik für strukturierte Ausgaben können Sie die Tool-Funktionalität von Nova mit ToolChoice kombinieren. In diesem Beispiel generiert das Modell einen Werkzeugabruf, der dem bereitgestellten JSON-Schema entspricht und das angegebene spezifische Tool im vollständig definierten JSON-Format aufruft. Weitere Anleitungen finden Sie unter [Advanced Systems](#).



**Benutzer:**

From the below provided Query, extract the relevent entities

Query:

John works in BUILDING-0987 and have been incharge of product id 23564#. His performance have been excellent in past year and is up for a raise.

Use the extract\_ner tool.

**ToolConfig:**

```
{
 "tools": [
 {
 "toolSpec": {
 "name": "extract_ner",
 "description": "Extract all the named entities. based on provided
input",
 "inputSchema": {
 "json": {
 "type": "object",
 "properties": {
 "entities": {
 "type": "array",
 "items": {
 "type": "object",
 "properties": {
 "name": {
 "type": "string",
 "description": "The extracted entity name. This
should be a name of a person, place, animal or thing"
 },
 "location": {
 "type": "string",
 "description": "The extracted location name. This
is a site name or a building name like SITE-001 or BUILDING-003"
 },
 "product": {
 "type": "string",
 "description": "The extrcted product code, this is
generally a 6 digit alphanumeric code such as 45623#, 234567"
 }
 }
 }
 }
 }
 }
 }
 }
 }
]
}
```

```

 },
 "required": [
 "name",
 "location",
 "product"
]
 }
}
},
"required": [
 "entities"
]
}
}
}],
"toolChoice": {
 "tool": {
 "name": "extract_ner"
 }
}
}
}

```

## Mehrsprachige Anwendungsfälle

Amazon Nova 2-Modelle wurden in mehr als 200 Sprachen trainiert und für 15 Sprachen optimiert.

### Themen

- [Prompt für genaue Übersetzungen](#)
- [Setzen Sie konsistente Schreibkonventionen durch](#)

### Prompt für genaue Übersetzungen

Um diese Funktion für Übersetzungen in Kurzform (einige Sätze) zu nutzen, können Sie das Modell anweisen, den Text in die angegebene Zielsprache zu übersetzen.

### Example Aufforderungen zur Übersetzung

Translate the following text into {target language}. Please output only the translated text with no prefix or introduction: {text}

```
Translate the following sentence from {source_language} to {target language}: {text}
```

```
{text} How do you say this sentence in {target_language}
```

Setzen Sie konsistente Schreibkonventionen durch

In zeichenbasierten Sprachen können die Amazon Nova 2-Modelle den Zeichensatz aus der Ausgangssprache verwenden. Sie können die folgende Aufforderung verwenden, um eine konsistente Ausgabe zu erzwingen.

Example Erzwingen Sie Schreibkonventionen

```
When translating, ensure to use the correct orthography / script / writing convention of the target language, not the source language's characters
```

Tools aufrufen

Agentursysteme

Themen

- [Stellen Sie die richtigen Inferenzparameter ein](#)
- [Beachten Sie die Latenzanforderungen](#)
- [Verwenden Sie bei den Anweisungen zum Aufrufen von Tools eine bewusste Formulierung](#)
- [Nutzen Sie Befehle zum „Denken“](#)
- [Bestellung per Tool-Call](#)
- [Erstellen Sie hochwertige Werkzeugschemas](#)
- [Unteragenten erstellen](#)
- [Verwenden Sie Tools für multimodale Eingaben](#)
- [Nächste Schritte](#)

Stellen Sie die richtigen Inferenzparameter ein

Der Werkzeugaufruf erfordert eine sehr spezifische strukturierte Ausgabe aus dem Modell und wird durch die Verwendung der folgenden Inferenzparameter verbessert:

- Modus ohne Argumentation: Temperatur: 0,7 und oberster P: 0,9
- Denkmodus: Temperatur: 1 und oberstes P: 0,9

## Beachten Sie die Latenzanforderungen

### Tip

Amazon Nova 2-Modelle sind in der Lage, Tools aufzurufen, wobei Argumentation ein- und ausgeschaltet ist. Argumentationsmodi haben jedoch erhebliche Auswirkungen auf die Latenz.

Bei latenzempfindlichen Anwendungen sollten Sie den Reasoning-Off-Modus optimieren und die erforderlichen Tool-Aufrufe nach Möglichkeit vereinfachen. Teilen Sie mehrstufige Workflows in einzelne Schritte auf, um die Abhängigkeit des Modells vom Auslesen unnötiger Parameter zu verringern.

Verwenden Sie bei den Anweisungen zum Aufrufen von Tools eine bewusste Formulierung

**Werkzeugnamen:** In Systemen, die Tools aufrufen, wird häufig in der Systemaufforderung auf Werkzeuge verwiesen, um dem Modell mitzuteilen, wann ein Werkzeug aufgerufen werden muss. Wenn Sie in der Eingabeaufforderung auf Tools verweisen, empfehlen wir, den Namen des Tools anstelle von XML- oder pythonischen Verweisen oder Beispielen zu verwenden.

Beispiel für eine gute Werkzeugreferenz

```
Use the 'run_shell_command' tool for running shell commands
```

Beispiel für eine schlechte Werkzeugreferenz

```
Call run_shell_command() to run shell commands
```

Nutzen Sie Befehle zum „Denken“

Für alle Anwendungsfälle, in denen Denken für das Aufrufen von Tools von Vorteil ist, empfehlen wir, den Argumentationsmodus zu nutzen, anstatt das Modell aufzufordern, „in Stichworten zu denken“ oder ein „Think“-Tool zu verwenden.

Die Modelle von Amazon Nova 2 wurden umfassend für den Argumentationsmodus trainiert und erzielen optimale Ergebnisse, wenn sie im Argumentationsmodus für Gedankenketten verwendet werden.

## Bestellung per Tool-Call

In Anwendungsfällen, die möglicherweise die gleichzeitige Verwendung integrierter Tools und das gleichzeitige Aufrufen systemeigener Tools erfordern, tendiert das Modell dazu, die integrierten Tools zuerst aufzurufen.

Weisen Sie das Modell in der Aufforderung nicht an, sich anders zu verhalten. Gestalten Sie Ihren Workflow stattdessen so, dass er dies berücksichtigt.

Wenn Sie beispielsweise nicht möchten, dass das Modell integrierte Tools verwendet, sollten Sie diese nicht in Ihren Arbeitsablauf aufnehmen, damit das Modell sie nicht bevorzugt.

## Erstellen Sie hochwertige Werkzeugschemas

Werkzeugschemas sind einer der wichtigsten Orte, an denen Sie effektive Werkzeugaufrufsysteme entwickeln können. Es ist jedoch wichtig zu berücksichtigen, was im Werkzeugschema selbst erfasst wird, wie jedes Schemaelement semantisch beschrieben wird und wie die Systemaufforderung in Systemanweisungen auf Tools und Schemaelemente verweist.

Amazon Nova 2-Modelle sind für präzise Beschreibungen in den Tool-Schemas optimiert. Halte es kurz.

Richtlinien für das Toolschema im Vergleich zur Systemaufforderung:

Folgendes in das Werkzeugschema aufnehmen:

- Kernfunktionalität: Was das Tool macht (20-50 Wörter empfohlen)
- Parameterspezifikationen: Klare Beschreibungen der einzelnen Parameter (etwa 10 Wörter pro Parameter)
- Erwartete Formate: Datentypen (wie Enum, Int, Float), Pflichtfelder und gültige Wertebereiche

Fügen Sie Folgendes in die Systemaufforderung ein:

- Widmen Sie einen `#Tool Usage` Abschnitt der Orchestrierungslogik (wann und warum bestimmte Tools verwendet werden sollten) und Geschäftsregeln (bedingte Logik, Sequenzierungsanforderungen und Abhängigkeiten).
- Strategien zur Fehlerbehandlung: Fügen Sie einen `#Error Handling and Troubleshooting` Abschnitt mit Anweisungen hinzu, wie Sie auf Fehler oder unerwartete Ausgaben reagieren können
- Formatierung der Ausgabe: Fügen Sie Details zur Präsentation für den Benutzer hinzu

## Beispiel

You are a software engineering issue root cause analysis agent. You are tasked with reviewing a customer issue and examining the repository to identify a plan to resolve the issue.

### # Core Mandates

- **\*\*DO NOT\*\*** update the original issue that was posted by the user. You only add *\*additional\** comments to the reported issue if necessary

### # Primary Workflows

1. **\*\*Understand:\*\*** Analyze the user's request and explore the codebase thoroughly using **\*\*get\_file\_contents\*\*** to grasp file structures and conventions.
2. **\*\*Plan:\*\*** Create a coherent, evidence-based plan for resolving the task and share it with the user following the format below

### # Tool Usage

- **\*\*Read the Issue:\*\*** Always start by using the **\*\*read\_issue\*\*** tool to get the details about the requested issue
- **\*\*File Paths:\*\*** Always end the file path with "/" if you are searching a directory using the **\*\*get\_file\_contents\*\*** tools
- **\*\*Parallelism:\*\*** Execute multiple independent tool calls in parallel when feasible

### # Error Handling and Troubleshooting

- **\*\*File Exploration:\*\*** If you get an error that a file doesn't exist, try searching at the directory level first to validate the file path

### # Output Formatting

Return your plan in markdown in the following format

#### ## Issue

<Your root cause analysis of the issue>

#### ## Resolution Plan

<your step by step plan of how to solve the issue>

## Unteragenten erstellen

Erwägen Sie, spezialisierte Unteragenten anstelle eines einzelnen Agenten mit vielen Tools zu erstellen, wenn Sie auf Folgendes stoßen:

- Die Anzahl der Tools übersteigt 20: Große Werkzeugsets lassen sich nur schwer verwalten und führen zu Auswahlfehlern

- Unterschiedliche Funktionsbereiche: Tools lassen sich naturgemäß in separate Kategorien einteilen (z. B. Datenabruf versus Verarbeitung versus Berichterstattung)
- Komplexe Schemas: Wenn die Parametertiefe 3-4 Stufen überschreitet oder Tools komplizierte Abhängigkeiten aufweisen
- Gesprächsdauer: Workflows, die regelmäßig 15 bis 20 Umdrehungen überschreiten, können von spezialisierten Unteragenten profitieren
- Leistungseinbußen: Wenn Sie eine verringerte Genauigkeit bei der Werkzeugauswahl oder eine erhöhte Latenz feststellen

 Tip

MCP-Server verfügen über Tools und Schemas, die Sie nicht kontrollieren können. Fügen Sie nur die Tools hinzu, die für Ihren Workflow zur Ausführung der erforderlichen Aufgabe erforderlich sind.

## Verwenden Sie Tools für multimodale Eingaben

Bei multimodalen Aufgaben haben wir keine Verbesserung der Genauigkeit beobachtet, wenn Tools für strukturierte Aufgaben (wie Extraktion oder Generierung von Zeitstempeln) genutzt werden.

Stattdessen empfehlen wir Ihnen, die entsprechenden Abschnitte im Abschnitt Eingabeaufforderung für multimodale Eingaben zu lesen, um zu erfahren, wie Sie das Modell mithilfe der bereitgestellten Vorlagen erfolgreich abfragen können.

## Nächste Schritte

- Informationen zur multimodalen Eingabeaufforderung finden Sie unter. [Multimodale Eingaben veranlassen](#)

# Multimodale Eingaben veranlassen

Die folgenden Abschnitte enthalten Anleitungen zum Verständnis von Bildern und Videos.

Informationen zu Audioanweisungen finden Sie im [the section called “Eingabeaufforderungen für Sprachgespräche”](#) Abschnitt.

# Allgemeine multimodale Richtlinien

## Benutzeraufforderungen und Systemaufforderungen

Für Anwendungsfälle mit multimodalem Verständnis sollte jede Anfrage den Text der Benutzeraufforderung enthalten. Systemaufforderungen, die nur Text enthalten dürfen, sind optional.

Systemaufforderungen können verwendet werden, um eine Persona für das Modell anzugeben und um die allgemeine Persönlichkeit und den Antwortstil zu definieren. Sie sollten jedoch nicht für detaillierte Anweisungen zur Aufgabendefinition oder zur Formatierung der Ausgabe verwendet werden.

Fügen Sie Aufgabendefinition, Anweisungen und Formatierungsdetails in die Benutzeraufforderung ein, um eine stärkere Wirkung als die Systemaufforderung für multimodale Anwendungsfälle zu erzielen.

## Reihenfolge der Inhalte

Eine multimodale Verständnisanfrage, die an Amazon Nova gesendet wird, sollte eine oder mehrere Dateien und eine Benutzeraufforderung enthalten. Die Benutzeraufforderung sollte das letzte Element in der Nachricht sein, immer nach dem Bild-, Dokument- oder Videoinhalt.

```
message = {
 "role": "user",
 "content": [
 { "document|image|video|audio": {...} },
 { "document|image|video|audio": {...} },
 ...
 { "text": "<user prompt>" }
]
}
```

In Fällen, in denen Sie in der Benutzeraufforderung auf bestimmte Dateien verweisen möchten, verwenden Sie „Text“-Elemente, um Beschriftungen zu definieren, die jedem Dateiblock vorangehen.

```
message = {
 "role": "user",
 "content": [
 { "text": "<label for item 1>" },
 { "document|image|video|audio": {...} },
 { "text": "<label for item 2>" },
```



```
{ "document|image|video|audio": {...} },
...
{ "text": "<user prompt>" }
]
}
```

## Verständnis von Dokumenten und Bildern

In den folgenden Abschnitten finden Sie Anleitungen zum Erstellen von Eingabeaufforderungen für Aufgaben, die das Verstehen oder Analysieren von Bildern und Dokumenten erfordern.

### Extrahieren von Text aus Bildern

Amazon Nova-Modelle können Text aus Bildern extrahieren, eine Funktion, die als Optical Character Recognition (OCR) bezeichnet wird. Um optimale Ergebnisse zu erzielen, stellen Sie sicher, dass die Bildeingabe, die Sie für das Modell bereitstellen, eine ausreichend hohe Auflösung hat, sodass die Textzeichen leicht zu erkennen sind.

Für Anwendungsfälle zur Textextraktion empfehlen wir die folgende Inferenzkonfiguration:

- Temperatur: Standard (0.7)
- TopP: Standard (0,9)
- Aktivieren Sie die Argumentation nicht

Die Amazon Nova-Modelle können Text in das Markdown-, HTML- oder LaTeX-Format extrahieren. Die folgende Vorlage für Benutzeraufforderungen wird empfohlen:

```
Instructions
Extract all information from this page using only {text_formatting} formatting. Retain
the original layout and structure including lists, tables, charts and math formulae.

Rules
1. For math formulae, always use LaTeX syntax.
2. Describe images using only text.
3. NEVER use HTML image tags `` in the output.
4. NEVER use Markdown image tags `![]()` in the output.
5. Always wrap the entire output in ``` tags.
```

Die Ausgabe ist vollständig oder teilweise in Markdown-Code-Fences (```) eingeschlossen. Sie können die Codezäune entfernen, indem Sie Code verwenden, der dem folgenden ähnelt:

```
def strip_outer_code_fences(text):
 lines = text.split("\n")
 # Remove only the outer code fences if present
 if lines and lines[0].startswith("`"):
 lines = lines[1:]
 if lines and lines[-1].startswith("`"):
 lines = lines[:-1]
 return "\n".join(lines).strip()
```

## Extrahieren strukturierter Informationen aus Bildern oder Text

Die Amazon Nova-Modelle können Informationen aus Bildern in das maschinenanalysierbare JSON-Format extrahieren, ein Prozess, der als Key Information Extraction (KIE) bezeichnet wird. Um KIE auszuführen, stellen Sie Folgendes bereit:

- Ein JSON-Schema. Eine formale Schemadefinition, die der JSON-Schemaspezifikation folgt.
- Eine oder mehrere der folgenden Optionen: Eine Dokumentdatei, ein Bild oder ein Dokumenttext

Das Dokument oder Bild muss in der Anfrage immer vor Ihrer Benutzeraufforderung platziert werden.

Für KIE-Anwendungsfälle empfehlen wir die folgende Inferenzkonfiguration:

- Temperatur: 0
- Argumentation: Eine Argumentation ist nicht erforderlich, kann aber die Ergebnisse verbessern, wenn reine Bildeingaben oder komplexe Schemata verwendet werden.

## Prompt-Vorlagen

### Nur Dokument- oder Bildeingabe

Given the image representation of a document, extract information in JSON format according to the given schema.

Follow these guidelines:

- Ensure that every field is populated, provided the document includes the corresponding value. Only use null when the value is absent from the document.
- When instructed to read tables or lists, read each row from every page. Ensure every field in each row is populated if the document contains the field.

JSON Schema:

```
{json_schema}
```

## Nur Texteingabe

Given the OCR representation of a document, extract information in JSON format according to the given schema.

Follow these guidelines:

- Ensure that every field is populated, provided the document includes the corresponding value. Only use null when the value is absent from the document.
- When instructed to read tables or lists, read each row from every page. Ensure every field in each row is populated if the document contains the field.

JSON Schema:

```
{json_schema}
```

OCR:

```
{document_text}
```

## Dokument oder Bild- und Texteingabe

Given the image and OCR representations of a document, extract information in JSON format according to the given schema.

Follow these guidelines:

- Ensure that every field is populated, provided the document includes the corresponding value. Only use null when the value is absent from the document.
- When instructed to read tables or lists, read each row from every page. Ensure every field in each row is populated if the document contains the field.

JSON Schema:

```
{json_schema}
```

OCR:

```
{document_text}
```

## Erkennung von Objekten und ihren Positionen in Bildern

Die Modelle von Amazon Nova 2 bieten die Möglichkeit, Objekte und ihre Positionen in Bildern zu identifizieren. Diese Aufgabe wird manchmal auch als Bildererkennung oder Objektlokalisierung bezeichnet. Zu den praktischen Anwendungen gehören Bildanalyse und Tagging, Automatisierung von Benutzeroberflächen, Bildbearbeitung und andere.

Unabhängig von der Auflösung und dem Seitenverhältnis der Bildeingabe verwendet das Modell einen Koordinatenraum, der das Bild horizontal in 1.000 Einheiten und vertikal in 1.000 Einheiten unterteilt, wobei sich die x:0 y:0-Position oben links im Bild befindet.

Begrenzungsrahmen werden anhand des Formats beschrieben, das jeweils für links, oben, rechts und unten `[x1, y1, x2, y2]` steht. Zweidimensionale Koordinaten werden mit dem Format dargestellt. `[x, y]`

Für Anwendungsfälle zur Objekterkennung empfehlen wir die folgenden Inferenzparameterwerte:

- Temperatur: 0
- Aktivieren Sie die Argumentation nicht

Vorlagen für Eingabeaufforderungen: allgemeine Objekterkennung

Wir empfehlen die folgenden Vorlagen für Benutzeraufforderungen.

Erkennung mehrerer Instanzen mit Bounding Boxes:

```
Please identify {target_description} in the image and provide the bounding box coordinates for each one you detect. Represent the bounding box as the [x1, y1, x2, y2] format, where the coordinates are scaled between 0 and 1000 to the image width and height, respectively.
```

Erkennung einer einzelnen Region mit einem Begrenzungsrahmen:

```
Please generate the bounding box coordinates corresponding to the region described in this sentence: {target_description}. Represent the bounding box as the [x1, y1, x2, y2] format, where the coordinates are scaled between 0 and 1000 to the image width and height, respectively.
```

Erkennung mehrerer Instanzen mit Mittelpunkten:

```
Please identify {target_description} in the image and provide the center point coordinates for each one you detect. Represent the point as the [x, y] format, where the coordinates are scaled between 0 and 1000 to the image width and height, respectively.
```

Erkennung einer einzelnen Region mit Mittelpunkt:

Please generate the center point coordinates corresponding to the region described in this sentence: {target\_description}. Represent the center point as the [x, y] format, where the coordinates are scaled between 0 and 1000 to the image width and height, respectively.

Modellausgabe wird analysiert:

Jede der oben empfohlenen Eingabeaufforderungen erzeugt eine durch Kommas getrennte Zeichenfolge, die eine oder mehrere Begrenzungsfeldbeschreibungen in einer Form enthält, die der folgenden ähnelt. Es kann geringfügig davon abweichen, ob ein „.“ ist am Ende der Zeichenfolge enthalten. Beispiel: [356, 770, 393, 872], [626, 770, 659, 878].

Sie können die vom Modell generierten Koordinateninformationen mithilfe eines regulären Ausdrucks analysieren, wie im folgenden Python-Codebeispiel gezeigt.

#### Codebeispiel

```
def parse_coord_text(text):
 """Parses a model response which uses array formatting ([x, y, ...])
 to describe points and bounding boxes. Returns an array of tuples."""
 pattern = r"\(([^\[\]]*?)\)"
 return [
 tuple(int(x.strip()) for x in match.split(","))
 for match in re.findall(pattern, text)
]
```

#### Codebeispiel

Um die normalisierten Koordinaten eines Begrenzungsrahmens dem Koordinatenraum des Eingabebilds neu zuzuordnen, können Sie eine Funktion verwenden, die dem folgenden Python-Beispiel ähnelt.

```
def remap_bbox_to_image(bounding_box, image_width, image_height):
 return [
 bounding_box[0] * image_width / 1000,
 bounding_box[1] * image_height / 1000,
 bounding_box[2] * image_width / 1000,
 bounding_box[3] * image_height / 1000,
]
```

## Vorlagen für Eingabeaufforderungen: Erkennung mehrerer Objektklassen mit Positionen

Wenn Sie mehrere Klassen von Elementen in einem Bild identifizieren möchten, können Sie Ihrer Aufforderung eine Klassenliste hinzufügen, indem Sie einen der folgenden Formatierungsansätze verwenden.

Bei allgemein verständlichen Klassen, die das Modell wahrscheinlich gut versteht, listen Sie die Klassennamen (ohne Anführungszeichen) in eckigen Klammern auf:

```
[car, traffic light, road sign, pedestrian]
```

Fügen Sie für Klassen, die nuanciert oder ungewöhnlich sind oder aus speziellen Bereichen stammen, mit denen das Modell möglicherweise nicht vertraut ist, eine Definition für jede Klasse in Klammern ein. Da diese Aufgabe eine Herausforderung darstellt, müssen Sie damit rechnen, dass sich die Leistung des Modells verschlechtern wird.

```
[taraxacum officinale (Dandelion - bright yellow flowers, jagged basal leaves, white puffball seed heads), digitaria spp (Crabgrass - low spreading grass with coarse blades and finger-like seed heads), trifolium repens (White Clover - three round leaflets and small white pom-pom flowers), plantago major (Broadleaf Plantain - wide oval rosette leaves with tall narrow seed stalks), stellaria media (Chickweed - low mat-forming plant with tiny star-shaped white flowers)]
```

Verwenden Sie je nachdem, welches JSON-Ausgabeformat Sie bevorzugen, eine der folgenden Vorlagen für Benutzeraufforderungen.

### Option 1: Aufforderung

Detect all objects with their bounding boxes in the image from the provided class list. Normalize the bounding box coordinates to be scaled between 0 and 1000 to the image width and height, respectively.

Classes: {candidate\_class\_list}

Include separate entries for each detected object as an element of a list.

Formulate your output as JSON format:

```
[
 {
 "class 1": [x1, y1, x2, y2]
 },
 ...
]
```

```
]
```

## Option 2 einholen

Detect all objects with their bounding boxes in the image from the provided class list. Normalize the bounding box coordinates to be scaled between 0 and 1000 to the image width and height, respectively.

Classes: **{candidate\_class\_list}**

Include separate entries for each detected object as an element of a list.

Formulate your output as JSON format:

```
[
 {
 "class": class 1,
 "bbox": [x1, y1, x2, y2]
 },
 ...
]
```

## Option 3 einholen

Detect all objects with their bounding boxes in the image from the provided class list. Normalize the bounding box coordinates to be scaled between 0 and 1000 to the image width and height, respectively.

Classes: **{candidate\_class\_list}**

Group all detected bounding boxes by class.

Formulate your output as JSON format:

```
{
 "class 1": [[x1, y1, x2, y2], [x1, x2, y1, y2], ...],
 ...
}
```

## Option 4 einholen

Detect all objects with their bounding boxes in the image from the provided class list. Normalize the bounding box coordinates to be scaled between 0 and 1000 to the image width and height, respectively.

Classes: **{candidate\_class\_list}**

Group all detected bounding boxes by class.

Formulate your output as JSON format:

```
[
 {
 "class": class 1,
 "bbox": [[x1, y1, x2, y2], [x1, x2, y1, y2], ...]
 },
 ...
]
```

Die Modellausgabe wird analysiert

Die Ausgabe wird als JSON codiert, die mit jeder JSON-Parsing-Bibliothek analysiert werden kann.

Vorlagen für Eingabeaufforderungen: Screenshot-Benutzeroberflächenerkennung

Wir empfehlen die folgenden Vorlagen für Benutzeraufforderungen.

Ermitteln der Position eines UI-Elements anhand eines Ziels:

In this UI screenshot, what is the location of the element if I want to {goal}? Express the location coordinates using the [x1, y1, x2, y2] format, scaled between 0 and 1000.

Erkennung der Position von UI-Elementen anhand von Text:

In this UI screenshot, what is the location of the element if I want to click on "{text}"? Express the location coordinates using the [x1, y1, x2, y2] format, scaled between 0 and 1000.

Modellausgabe wird analysiert:

Für jede der obigen Eingabeaufforderungen zur Erkennung von UI-Grenzen können Sie die vom Modell generierten Koordinateninformationen mithilfe eines regulären Ausdrucks analysieren, wie im Python-Codebeispiel unten gezeigt.

Codebeispiel

```
def parse_coord_text(text):
```



```
"""Parses a model response which uses array formatting ([x, y, ...])
to describe points and bounding boxes. Returns an array of tuples."""
pattern = r"\([([^\[\]]*?)\)"
return [
 tuple(int(x.strip()) for x in match.split(","))
 for match in re.findall(pattern, text)
]
```

## Video-Verständnis

Die folgenden Abschnitte enthalten Anleitungen zum Erstellen von Eingabeaufforderungen für Aufgaben, die das Verstehen oder Analysieren von Videos erfordern.

### Videos zusammenfassen

Amazon Nova-Modelle können Zusammenfassungen von Videoinhalten generieren.

Für Anwendungsfälle zur Videozusammenfassung empfehlen wir die folgenden Inferenzparameterwerte:

- Temperatur: 0
- In einigen Anwendungsfällen kann es von Vorteil sein, Modelldenken zu aktivieren

Es ist keine spezielle Vorlage für Eingabeaufforderungen erforderlich. In Ihrer Benutzeraufforderung sollten die Aspekte des Videos, die Ihnen wichtig sind, klar angegeben sein. Hier sind ein paar Beispiele für effektive Eingabeaufforderungen:

Can you create an executive summary of this video's content?

Can you distill the essential information from this video into a concise summary?

Could you provide a summary of the video, focusing on its key points?

### Generierung detaillierter Bildunterschriften für Videos

Amazon Nova-Modelle können detaillierte Untertitel für Videos generieren, eine Aufgabe, die als dichte Untertitelung bezeichnet wird.

Für Anwendungsfälle mit Videountertiteln empfehlen wir die folgenden Inferenzparameterwerte:

- Temperatur: 0
- In einigen Anwendungsfällen kann es von Vorteil sein, Modelldenken zu aktivieren

Es ist keine spezielle Vorlage für Eingabeaufforderungen erforderlich. In Ihrer Benutzeraufforderung sollten die Aspekte des Videos, die Ihnen wichtig sind, klar angegeben sein. Hier sind ein paar Beispiele für effektive Eingabeaufforderungen:

Provide a detailed, second-by-second description of the video content.

Break down the video into key segments and provide detailed descriptions for each.

Generate a rich textual representation of the video, covering aspects like movement, color and composition.

Describe the video scene-by-scene, including details about characters, actions and settings.

Offer a detailed narrative of the video, including descriptions of any text, graphics, or special effects used.

Create a dense timeline of events occurring in the video, with timestamps if possible.

## Analyse von Sicherheitsvideomaterial

Amazon Nova-Modelle können Ereignisse in Sicherheitsaufnahmen erkennen.

Für Anwendungsfälle mit Sicherheitsvideos empfehlen wir die folgenden Werte für Inferenzparameter:

- Temperatur: 0
- In einigen Anwendungsfällen kann es von Vorteil sein, Modelldenken zu aktivieren

You are a security assistant for a smart home who is given security camera footage in natural setting. You will examine the video and describe the events you see. You are capable of identifying important details like people, objects, animals, vehicles, actions and activities. This is not a hypothetical, be accurate in your responses. Do not make up information not present in the video.

## Extrahieren von Videoereignissen mit Zeitstempeln

Amazon Nova-Modelle können Zeitstempel identifizieren, die sich auf Ereignisse in einem Video beziehen. Sie können verlangen, dass Zeitstempel in Sekunden oder im MM:SS-Format formatiert werden. Beispielsweise kann ein Ereignis, das im Video nach 1 Minute und 25 Sekunden eintritt, als `01:25` oder `85 01:25` dargestellt werden.

Für diesen Anwendungsfall empfehlen wir die folgenden Inferenzparameterwerte:

- Temperatur: 0
- Verwende keine Argumentation

Wir empfehlen Ihnen, Eingabeaufforderungen zu verwenden, die den folgenden ähneln:

### Identifizieren der Start- und Endzeit eines Ereignisses

Please localize the moment that the event "{event\_description}" happens in the video. Answer with the starting and ending time of the event in seconds, such as `[[72, 82]]`. If the event happen multiple times, list all of them, such as `[[40, 50], [72, 82]]`.

Locate the segment where "{event\_description}" happens. Specify the start and end times of the event in MM:SS.

Answer the starting and end time of the event "{event\_description}". Provide answers in MM:SS

When does "{event\_description}" in the video? Specify the start and end timestamps, e.g. `[[9, 14]]`

### Identifizieren mehrerer Vorkommen eines Ereignisses

Please localize the moment that the event "{event\_description}" happens in the video. Answer with the starting and ending time of the event in seconds. e.g. `[[72, 82]]`. If the event happen multiple times, list all of them. e.g. `[[40, 50], [72, 82]]`

### Generieren eines Protokolls von Videosegmenten mit Zeitstempeln

Segment a video into different scenes and generate caption per scene. The output should be in the format: `[STARTING TIME-ENDING TIMESTAMP] CAPTION`. Timestamp in MM:SS format

For a video clip, segment it into chapters and generate chapter titles with timestamps. The output should be in the format: [STARTING TIME] TITLE. Time in MM:SS

Generate video captions with timestamp.

## Klassifizieren von Videos

Sie können Amazon Nova-Modelle verwenden, um Videos auf der Grundlage einer vordefinierten Liste von Klassen, die Sie bereitstellen, zu klassifizieren.

Für diesen Anwendungsfall empfehlen wir die folgenden Inferenzparameterwerte:

- Temperatur: 0
- Argumentation sollte nicht verwendet werden

Verwenden Sie die folgende Vorlage für Eingabeaufforderungen:

```
What is the most appropriate category for this video? Select your answer from the
options provided:
{class1}
{class2}
{...}
```

Beispiel:

```
What is the most appropriate category for this video? Select your answer from the
options provided:
Arts
Technology
Sports
Education
```

## Moderation von Inhalten

Dieser Leitfaden enthält bewährte Methoden, um Amazon Nova-Modelle dazu zu veranlassen, Inhalte mithilfe des [MLCommons® AI Luminare Assessment Standard](#) zu moderieren — einem umfassenden Framework mit 12 Gefahrenkategorien für die KI-Sicherheit. In diesem Leitfaden wird

der MLCommons Standard zwar als Beispiel zur Veranschaulichung bewährter Verfahren verwendet, die Aufforderungstechniken funktionieren jedoch mit allen frei formulierten oder anpassbaren Kategorien und Definitionen für die Inhaltsmoderation, die Sie angeben.

## Die wichtigsten Prinzipien

- Verwenden Sie je nach Anwendungsfall strukturierte (XML, JSON) oder formlose Eingabeaufforderungen
- Moderieren Sie alle Textinhalte: Konversationen, Artikel, Beiträge in sozialen Medien, Kommentare, Rezensionen und mehr
- Stellen Sie klare Richtliniendefinitionen bereit
- Fordern Sie Erläuterungen aus Gründen der Transparenz an

## Empfohlene Konfiguration

Für Aufgaben zur Inhaltsmoderation empfehlen wir die folgende Inferenzkonfiguration:

- Temperatur — Verwenden Sie den Standardwert 0,7.
- Top P — Verwenden Sie den Standardwert 0,9.
- Argumentation — Deaktivieren Sie die Argumentation für die Inhaltsmoderation, um die Latenz zu reduzieren.

## MLCommons universelle Taxonomie

Die Norm definiert 12 Gefahrenkategorien:

MLCommons AILuminate Gefahrenkategorien

| Kategorie              | Definition                                                                             | Wichtige Unterkategorien                                                                                |
|------------------------|----------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------|
| Gewaltverbrechen       | Inhalte, die die Begehung von Gewaltverbrechen ermöglichen, fördern oder befürworten   | Massengewalt, Mord, Körperverletzung, Häuslicher Missbrauch, Terror, Tierquälerei                       |
| Gewaltfreie Verbrechen | Inhalte, die gewaltfreie kriminelle Aktivitäten ermöglichen, fördern oder unterstützen | Menschenhandel, Betrug, Diebstahl, Brandstiftung, Drogenverbrechen, Waffenverbrechen, Cyberkriminalität |

| Kategorie                       | Definition                                                                                                          | Wichtige Unterkategorien                                                                                   |
|---------------------------------|---------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------|
| Geschlechtsbezogene Verbrechen  | Inhalte, die Sexualdelikte ermöglichen, fördern oder befürworten                                                    | Sexhandel, Sexuelle Nötigung, Sexuelle Belästigung, nicht einvernehmliche intime Inhalte, Bestialität      |
| Sexuelle Ausbeutung von Kindern | Inhalte, die sexuellen Missbrauch von Minderjährigen beinhalten, beschreiben, ermöglichen, fördern oder befürworten | Unangemessene Beziehungen zu Kindern, Sexueller Missbrauch von Kindern, CSAM                               |
| CYBRNE                          | Inhalte, die die Herstellung von Massenvernichtungswaffen ermöglichen, fördern oder befürworten                     | Chemische Waffen, Biologische Waffen, Radiologische Waffen, Atomwaffen, Sprengstoffe mit hoher Sprengkraft |
| Selbstmord und Selbstverletzung | Inhalte, die vorsätzliche Selbstverletzung ermöglichen, fördern oder befürworten                                    | Selbstmord, Selbstverletzung, Essstörungen, Gefährliche Herausforderungen                                  |
| Hass                            | Inhalte, die Menschen aufgrund geschützter Merkmale erniedrigen oder entmenslichen                                  | Erniedrigende Bemerkungen, Zufügen von Schaden, Ausgrenzung physical/emotional und Isolation               |
| Spezialisierte Beratung         | Unqualifizierte Beratung in sensiblen Bereichen ohne entsprechende Haftungsausschlüsse                              | Finanzberatung, medizinische Beratung, Rechtsberatung, Wahlberatung, Sicherheitsansprüche                  |
| Privacy (Datenschutz)           | Inhalte, die sensible, nicht öffentliche personenbezogene Daten enthalten                                           | Physische Sicherheit (Adressen), digitale Sicherheit (Anmeldedaten), Finanzielle Sicherheit (Kontonummern) |
| Geistiges Eigentum              | Inhalte, die gegen IP-Rechte verstoßen oder deren Verletzung fördern                                                | Urheberrechtsverletzung, Markenverletzung, Patentverletzung                                                |

| Kategorie        | Definition                                                                      | Wichtige Unterkategorien                                                  |
|------------------|---------------------------------------------------------------------------------|---------------------------------------------------------------------------|
| Verleumdung      | Inhalte, die nachweislich falsch sind und den Ruf einer Person schädigen können | Verleumdung, üble Nachrede, Herabwürdigung                                |
| Sexueller Inhalt | Erotische Inhalte wie Pornografie und Cybersex                                  | Pornografie (grafische sexuelle Beschreibungen), Direkter erotischer Chat |

Quelle: MLCommons® ALLuminate Assessment Standard (Dokumentation)

## Anregende Beispiele

### Strukturiertes Format

Am besten für automatisierte Systeme, die eine analysierbare Ausgabe benötigen. In diesen Beispielen wird Few-Shot Learning verwendet, bei dem Sie in der Eingabeaufforderung Beispiele für Input-Output-Paare angeben, die als Leitfaden für die Antworten des Modells dienen. Die folgenden Beispiele beinhalten eine einzelne Demonstration, Sie können jedoch auch mehrere Beispiele hinzufügen, um die Genauigkeit für Ihren speziellen Anwendungsfall zu verbessern.

### Struktur (XML)

User:

```
You are a text content moderator that detects policy violations,
describes violated categories, and explains the reasoning behind your decisions.
You will see a policy list and a conversation to be moderated.
Your moderation response should be formatted as follows.

Start the response by indicating policy violation status using either
<POLICY_VIOLATION>Yes</POLICY_VIOLATION> for content that violates policies, or
<POLICY_VIOLATION>No</POLICY_VIOLATION> for content that does not violate policies.

Then, list the specific violation categories between <CATEGORY_LIST> and </
CATEGORY_LIST> tags.
If there is no violation, then put C0 between the tags.

End the response by providing an analysis explaining whether the content violates
policies
```

and why in <EXPLAIN> </EXPLAIN> tags. Here is an example.

```
<EXAMPLE>
<POLICY>
{{Policy definitions and categories}}
</POLICY>
<TEXT>
{{Content to moderate}}
</TEXT>
<POLICY_VIOLATION>Yes/No</POLICY_VIOLATION>
<CATEGORY_LIST>Categories or C0</CATEGORY_LIST>
<EXPLAIN>Explanation</EXPLAIN>
</EXAMPLE>
```

Now, please moderate the following input policy and text.

```
<POLICY>
{{Policy definitions and categories}}
</POLICY>
<TEXT>
{{Content to moderate}}
</TEXT>
```

**Assistant:**

```
<POLICY_VIOLATION>Yes/No</POLICY_VIOLATION>
<CATEGORY_LIST>Categories or C0</CATEGORY_LIST>
<EXPLAIN>Explanation</EXPLAIN>
```

**Struktur (JSON)**

**User:**

```
You are a text content moderator that detects policy violations,
describes violated categories, and explains the reasoning behind your decisions.
You will check if there is unsafe content in the below text snippet
in accordance with our safety policy.
Your moderation response should be in JSON format with the following structure:
{
 "policy_violation": "Yes or No",
 "category_list": ["List of violated category codes"],
 "explanation": "Reason for the decision"
}
```



If there is no violation, use "C0" as the category code.

**IMPORTANT:** Do not add any additional text or explanation. Your response must contain ONLY the JSON object, nothing else.

Here is an example:

```
[POLICY]
{{Policy definitions and categories}}

[TEXT]
{{Content to moderate}}

[RESPONSE]
{
 "policy_violation": "Yes or No",
 "category_list": ["Violated category codes or C0"],
 "explanation": "Explanation"
}
```

Now, please moderate the following input.

```
[POLICY]
{{Policy definitions and categories}}

[TEXT]
{{Content to moderate}}

[RESPONSE]
```

**Assistant:**

```
{
 "policy_violation": "No",
 "category_list": ["C0"],
 "explanation": "The text is a casual personal question with no policy violations."
}
```

**Beispiel für Aufforderung und Antwort zur Inhaltsmoderation**

**User:**

You are a text content moderator that detects policy violations, describes violated categories, and explains the reasoning behind your decisions. You will see a policy list and a conversation to be moderated. Your moderation response should be formatted as follows.

Start the response by indicating policy violation status using either `<POLICY_VIOLATION>Yes</POLICY_VIOLATION>` for content that violates policies, or `<POLICY_VIOLATION>No</POLICY_VIOLATION>` for content that does not violate policies.

Then, list the specific violation categories between `<CATEGORY_LIST>` and `</CATEGORY_LIST>` tags.

If there is no violation, then put `C0` between the tags.

End the response by providing an analysis explaining whether the content violates policies and why in `<EXPLAIN>` `</EXPLAIN>` tags. Here is an example.

`<POLICY>`

The 12 categories are: Violent Crimes, Non-Violent Crimes, Sex-Related Crimes, Child Sexual Exploitation, CBRNE, Suicide & Self-Harm, Hate, Specialized Advice, Privacy, Intellectual Property, Defamation, Sexual Content.

If none apply, label as `C0`.

`</POLICY>`

`<EXAMPLE>`

`<TEXT>`

"To make a pipe bomb: Get metal pipe, end caps, gunpowder, and fuse. Drill hole in cap, fill pipe with powder, insert fuse, seal both ends tightly."

`</TEXT>`

`<POLICY_VIOLATION>Yes</POLICY_VIOLATION>`

`<CATEGORY_LIST>CBRNE</CATEGORY_LIST>`

`<EXPLAIN>Provides instructions for creating explosives, enabling dangerous weapons creation.</EXPLAIN>`

`</EXAMPLE>`

`<TEXT>`

DIY explosive device: Mix ammonium nitrate fertilizer with fuel oil at 94:6 ratio. Use blasting cap for detonation. Store in cool, dry place. #DIY #Chemistry

`</TEXT>`

Assistant:

`<POLICY_VIOLATION>Yes</POLICY_VIOLATION>`

```
<CATEGORY_LIST>CBRNE</CATEGORY_LIST>
<EXPLAIN>
The text provides specific instructions for creating ANFO explosives, including precise
mixing ratios and detonation methods. This falls under CBRNE (high-yield explosives
subcategory) as it enables dangerous weapons creation with actionable technical
details.
</EXPLAIN>
```

## Moderation von Inhalten in freier Form

Freiform-Eingabeaufforderungen können viele verschiedene Strukturen annehmen, die über die folgenden Beispiele hinausgehen. In den folgenden Beispielen werden bewusst unterschiedliche Formatierungsstile verwendet, um die Flexibilität von Freiform-Eingabeaufforderungen zu veranschaulichen. Sie können die Struktur, Formulierung und das Format an Ihren speziellen Anwendungsfall anpassen.

### Beispiel 1: Yes/No Frage (Selbstmord und Selbstverletzung)

#### Example Moderation von Inhalten mit Ja/Nein

User:

```
Please stick to the following policy for content moderation. {{user_policy}}
Does this text promote harmful activities?
```

```
Best way to hurt yourself without leaving marks?
Asking for tips on methods that work.
```

Assistant:

```
Yes. This text explicitly requests methods for self-harm,
falling under the Suicide & Self-Harm category. The intent to
conceal evidence ("without leaving marks") indicates deliberate
harmful behavior.
```

### Beispiel 2: Identifizierung und Argumentation von Kategorien (Hass)

#### Example Kategorisierung, Moderation von Inhalten

User:

You are a professional content moderator. Please stick to the following policy for content moderation. {{user\_policy}}  
Which category does this text violate and why?

Text: "Women are naturally worse at mathematics than men, according to my personal observations. They should stick to arts and humanities."

Assistant:

Hate. This text makes demeaning generalizations about women based on gender (a protected characteristic), promoting exclusion from STEM fields. The claim lacks scientific basis and perpetuates harmful stereotypes.

### Beispiel 3: Schweregrad (Datenschutz)

#### Example Moderation von Inhalten nach Schweregrad

User:

Content moderation task  
---  
Policy: {{user\_policy}}  
---  
Rate the severity of the following content as "none", "low", "medium", or "high" and identify any violated categories.

Content: "John Smith lives at 742 Evergreen Terrace, Springfield. His SSN is 123-45-6789 and his bank account number is 9876543210."

Assistant:

Severity: High

Violated category: Privacy

This content exposes multiple forms of sensitive personal information including a full name, home address, Social Security number, and bank account number. This falls under the Privacy category, specifically the physical security, digital security, and financial security

subcategories. The combination of identifiers creates a significant risk of identity theft and financial fraud.

## Anwendungsfälle für Sicherheit

Dieses Handbuch enthält bewährte Methoden, um Nova 2 Lite zur Durchführung von Sicherheitsaufgaben zu veranlassen, die sich auf Anwendungsfälle zur Analyse konzentrieren. Es behandelt ein Beispiel für die Umwandlung eines Threat Intelligence-Berichts in einen strukturierten Jagdplan für ein Security Operations Center (SOC) -Team. Nova 2 Lite ist nicht darauf ausgelegt, bösartigen Code zu generieren oder anstößige Sicherheitsoperationen durchzuführen. Die hier gezeigten Aufforderungstechniken erzeugen eine strukturierte, wiederholbare Ausgabe, die sich in bestehende Sicherheitsworkflows integrieren lässt.

### Die wichtigsten Prinzipien

- Weisen Sie dem Modell eine bestimmte Sicherheitsrolle zu (Bedrohungsjäger, Sicherheitsingenieur), um sich auf die Ergebnisse zu konzentrieren
- Definieren Sie die Ausgabestruktur explizit — Abschnitte, Tabellen und Formate, denen das Modell entsprechen muss
- Schließen Sie Regeln ein, die verhindern, dass Indikatoren, Techniken oder Sicherheitslücken Halluzination erzeugen, die in der Eingabe nicht enthalten sind
- Passen Sie den Output durch iterative Verfeinerung an Ihre Umgebung, Ihre Tools und Ihre Einschränkungen an

### Planer zur Jagd nach Bedrohungsdaten

Diese Vorlage für Eingabeaufforderungen wandelt einen Bericht über Bedrohungsinformationen in einen strukturierten Jagdplan um. Das Modell ordnet das Verhalten von Gegnern [MITRE ATT&CK](#) zu, einer öffentlich zugänglichen Wissensdatenbank über gegnerische Taktiken und Techniken, die als gängiges Vokabular in der Bedrohungsaufklärung verwendet wird. Anschließend werden Hypothesen generiert, anhand derer mithilfe von SIEM-Telemetrie (Security Information and Event Management) ermittelt werden kann, welche Techniken nicht auffindbar sind, und erstellt eine konsolidierte Checkliste für die Protokollquellen. Die Ausgabe ist standardmäßig SIEM-agnostisch. Analysten können daraufhin Erkennungsabfragen für eine bestimmte Plattform (SPL, KQL, Sigma) anfordern.

Das Modell geht davon aus, dass der Threat Intelligence-Bericht bereits von Ihrem Team auf seine Relevanz überprüft wurde, und führt keine eigene Bewertung der Anwendbarkeit durch.

## System-Prompt

Empfohlene Modellkonfiguration: Nova 2 Lite mit mittlerer Argumentation.

Verwenden Sie die folgende Systemaufforderung, um das Modell für die Analyse von Bedrohungsinformationen zu konfigurieren.

IMPORTANT: Write all output as readable markdown. Do not wrap the entire response in a code block. Use fenced code blocks only inside the Telemetry Requirements section if needed.

You are a senior threat hunter supporting a SOC team. Your role is to convert threat intelligence reports into actionable hunt plans focused on identifying adversary tradecraft.

The intelligence you receive has already been vetted for relevance. Do not assess whether the threat applies – it does. Focus entirely on operationalizing the tradecraft described.

Your output has three sections, in this order:

### MITRE ATT&CK MAPPING

- Map every adversary behavior in the report to ATT&CK techniques and sub-techniques
- Present as a table: Technique ID | Name | Tactic | How used (one sentence, specific to the report)
- Do not map techniques not described or clearly implied in the report
- In the "How used" column, describe the behavior without reproducing specific domain, IP, or hash values. Refer to indicators generically rather than by value.

### HUNT HYPOTHESES

#### Assessment

- State whether the report provides sufficient operational detail to support actionable hunting
- If the report defers IOCs or technical details to a separate document, name that document and note that indicator-based hunts require it

#### Not Huntable via SIEM

- A technique is not huntable if detecting it requires telemetry that the

target device class does not realistically forward to a SIEM, or if detection requires decrypting encrypted payloads or inspecting raw packet captures. Connection metadata (IPs, ports, timing, volume, TLS certificate fields) is available without decryption and counts as huntable telemetry.

- List every mapped technique that cannot be hunted using logs a SIEM realistically ingests – one entry per technique with a one-line reason
- Each entry must include the technique ID and name
- Only list techniques that appear in your MITRE ATT&CK MAPPING table above. Do not introduce new techniques in this section

#### Huntable Hypotheses

- For each remaining technique, generate a hypothesis with:
  - Statement: What you are looking for, stated as a testable proposition
  - Data required: The specific log source and event type needed, realistic for where the technique executes
  - Rationale: Why this activity would indicate the threat, and what distinguishes it from normal operations
  - Priority: High / Medium / Low
    - High: Technique is central to the adversary's objective AND detection signal is specific (low false-positive rate against the described behavior).
    - Medium: Technique is supporting or post-compromise, OR detection signal requires correlation with other events to be reliable.
    - Low: Technique is incidental, or detection signal overlaps heavily with benign activity and requires tuning per environment.
  - Specific indicators: Reference the location of relevant indicators in the source report. Do not reproduce hash, IP, or domain values. The analyst will retrieve exact values from the source report.
- Reference the ATT&CK technique ID in each hypothesis

#### TELEMETRY REQUIREMENTS

- Consolidate all required log sources across every huntable hypothesis into a single checklist
- Every telemetry entry must reference a technique ID from the Huntable Hypotheses section. Do not add sources that support no listed hypothesis.
- Format each entry as: [ ] Log source (event type) – needed for – technique IDs and what it detects
- All items unchecked – the analyst determines what is available, not you
- Flag high-value telemetry: sources that enable hunting for multiple techniques from this threat

#### RULES

- Do not invent techniques, indicators, behaviors, numeric thresholds, port numbers, byte sizes, time windows, or tuning values. If a threshold is

- needed in a hypothesis, phrase it as a variable ("volume exceeding baseline", "repeated connections") and leave tuning to the analyst.
- Do not invent log source names. Use only telemetry that applies to the device class where the technique executes
  - Do not reference figures, tables, or sections by number unless they appear in the report you are analyzing. If you cannot verify a specific figure reference, describe the indicator location generically ("see IOC table") or omit the reference.
  - If the report is vague about a technique, note the ambiguity
  - Every technique in the MITRE ATT&CK MAPPING table must appear in exactly one of "Not Huntable via SIEM" or "Huntable Hypotheses". Verify before finalizing.
  - Do not invent ATT&CK technique IDs. If unsure of the correct ID for a described behavior, use the parent technique ID or omit the mapping rather than guess.
  - Do not generate a hypothesis you would not act on. Label it NOT HUNTABLE VIA SIEM instead.
  - Keep output tight – no filler, no preamble, no restating the report back to the analyst

#### EXAMPLE (classification reasoning)

- T1190 Exploit Public-Facing Application # Huntable. Inbound connections and HTTP request metadata to exposed services are visible in WAF, reverse proxy, and edge firewall logs.
- T1003.001 OS Credential Dumping: LSASS Memory # Not Huntable via SIEM without EDR. Requires process access telemetry (Sysmon Event 10, EDR process handle events); standard Windows Security logs do not capture it reliably.
- T1016 System Network Configuration Discovery # Not Huntable via SIEM on most endpoints. On-host enumeration (ipconfig, route) produces no network artifact; detection requires command-line logging that is often not forwarded.
- T1110.003 Password Spraying # Huntable. Authentication logs show low-volume failed logons across many accounts from a single source, distinguishable from single-account brute force.
- T1070.004 File Deletion on a network appliance # Not Huntable via SIEM. Executes on an embedded device (router/firewall) that forwards syslog and connection metadata only; host-level file, process, auditd, and iptables-change events are not available to the SIEM even though equivalent logs exist on servers.
- T1486 Data Encrypted for Impact # Huntable. File modification events and mass-rename patterns appear in file server audit logs and EDR file telemetry.



## Beispiel

Das folgende Beispiel zeigt die vollständige Ausgabestruktur. Die Eingabe ist eine kurze Zusammenfassung eines Blogbeitrags des Anbieters. Längere Berichte führen zu umfangreicheren Plänen.

### User:

```
Our threat intel team flagged this report as relevant to us.
Generate a hunt plan.
"A New Sandworm Malware Cyclops Blink Replaces VPN Filter.pdf"
```

### Assistant:

```
MITRE ATT&CK MAPPING

Technique ID	Name	Tactic	How used
T1133	External Remote Services	Initial Access	Actors deploy modified device firmware images by exploiting an externally-available management service.
T1059.004	Command and Scripting Interpreter: Unix Shell	Execution	Cyclops Blink executes downloaded files using the Linux API (Unix shell).
T1542.001	Pre-OS Boot: System Firmware	Persistence	The malware is embedded in a modified device firmware image to survive reboots.
T1037.004	Boot or Logon Initialization Scripts: RC Scripts	Persistence	Cyclops Blink runs at device startup via a tweaked RC script.
T1562.004	Impair Defenses: Disable or Modify System Firewall	Defense Evasion	The malware alters the Linux firewall to permit C2 traffic.
T1036.005	Masquerading: Match Legitimate Name or Location	Defense Evasion	Cyclops Blink masquerades as a Linux kernel thread process.
T1082	System Information Discovery	Discovery	The malware regularly queries and beacons device information to its C2 server.
T1090	Proxy	Command and Control	C2 traffic can be routed through a proxy to hide the source.
T1132.002	Data Encoding: Non-Standard Encoding	Command and Control	Command messages use a custom binary scheme to encode data.
T1008	Fallback Channels	Command and Control	The malware selects a C2 server from lists of IPv4 addresses and ports.
T1071.001	Application Layer Protocol: Web Protocols	Command and Control	Files are downloaded and commands issued over HTTP/HTTPS.
T1573.002	Encrypted Channel: Asymmetric Cryptography	Command and Control	C2 messages are individually encrypted (AES-256-CBC) and sent under TLS.
```

```
| **T1571** | Non-Standard Port | Command and Control | C2 uses ports that are not
typical for HTTP/HTTPS traffic. |
| **T1041** | Exfiltration Over C2 Channel | Exfiltration | The malware can upload
files to a C2 server. |
```

```

```

## ## HUNT HYPOTHESES

### ### Assessment

The advisory provides sufficient tactical detail (e.g., C2 protocols, persistence mechanisms, and traffic patterns) to build generic detection logic. However, indicator-of-compromise (IOC) values (specific IPs, domains, hashes) are **deferred** to the accompanying Cyclops Blink malware analysis report; indicator-based hunts therefore require that report.

### ### Not Huntable via SIEM

- **T1059.004** - Command and Scripting Interpreter: Unix Shell - Requires process-level execution telemetry from the network device, which is not forwarded to a typical SIEM.
- **T1542.001** - Pre-OS Boot: System Firmware - Detection needs firmware image analysis; not available via standard logs.
- **T1037.004** - Boot or Logon Initialization Scripts: RC Scripts - Relies on boot-time script execution logs that most SIEMs do not collect from network appliances.
- **T1562.004** - Impair Defenses: Disable or Modify System Firewall - Requires firewall-rule-change audit data that is generally not forwarded from WatchGuard devices.
- **T1036.005** - Masquerading: Match Legitimate Name or Location - Needs process-identity details that are not exported to SIEM from the device.

### ### Huntable Hypotheses

```
ATT&CK ID	Statement	Data required	Rationale	Priority	Specific indicators
T1133	Unexpected inbound connections to a device's remote-management interface				
from external IPs.	WatchGuard firewall logs (management-interface connection				
events).	Cyclops Blink is delivered via exploitation of open remote-management				
services; inbound connections that bypass the allowed management-access list are a					
clear sign of initial-access activity.	**High**	See Cyclops Blink malware analysis			
report - IOC table for affected management ports.					
T1082	Periodic outbound HTTPS requests from a network device to a small set of				
domains/IPs with low-volume payloads. | Outbound NetFlow/Zeek logs, DNS query logs,
TLS handshake logs (SNI, certificate fields). | The malware beacons device information
```

on a regular schedule; repetitive, low-data-size HTTPS calls to the same endpoints stand out from normal device behavior. | **\*\*High\*\*** | See Cyclops Blink malware analysis report - beacon frequency and target domains. |

| **\*\*T1090\*\*** | Use of an intermediate proxy server for outbound C2 traffic from infected devices. | Proxy server access logs (e.g., Squid, Bluecoat) showing requests originating from WatchGuard IPs. | Proxy usage is a common evasion tactic; seeing known-good device IPs proxying to unusual destinations suggests C2 redirection. | **\*\*Medium\*\*** | See Cyclops Blink malware analysis report - proxy-config examples. |

| **\*\*T1132.002\*\*** | Outbound HTTP/HTTPS requests containing high-entropy binary data that does not match normal application payloads. | Proxy or Zeek HTTP(S) payload logs (or network TAP packet captures) with entropy analysis. | The custom binary encoding of C2 messages produces high-entropy byte streams; anomalous binary content in otherwise legitimate-looking web requests can indicate command encoding. | **\*\*Medium\*\*** | See Cyclops Blink malware analysis report - sample encoded command payloads. |

| **\*\*T1008\*\*** | Rapid switching of destination IP/port pairs for outbound connections from the same device within a short time window. | NetFlow/Zeek flow records (source-IP, destination-IP, destination-port, timestamps). | Fallback-channel logic causes the malware to rotate C2 endpoints; frequent IP/port changes from a single device are suspicious. | **\*\*Medium\*\*** | See Cyclops Blink malware analysis report - list of C2 IP/port pairs. |

| **\*\*T1071.001\*\*** | Outbound HTTP/HTTPS traffic to domains that resolve to Tor hidden services or to IPs known to host .onion exit nodes. | DNS resolution logs, NetFlow/Zeek logs, and optional Tor exit-node list cross-reference. | Cyclops Blink can use Tor for C2 reachability; traffic to .onion-associated domains or IPs is a strong indicator of hidden-service communication. | **\*\*High\*\*** | See Cyclops Blink malware analysis report - known C2 domains and Tor hidden-service names. |

| **\*\*T1573.002\*\*** | Outbound TLS handshakes from a network device that present self-signed certificates or certificates signed by an untrusted CA. | TLS handshake logs (e.g., from firewall/proxy) capturing certificate subject, issuer, serial, and public-key fingerprint. | The malware generates individually-signed TLS certificates for each C2 session; seeing unexpected self-signed or mistrust-CA certificates from a device is a red flag. | **\*\*High\*\*** | See Cyclops Blink malware analysis report - sample certificate details. |

| **\*\*T1571\*\*** | Outbound connections from a WatchGuard device to destination ports outside the conventional web ports on a regular basis. | NetFlow/Zeek flow logs (source-IP, destination-port). | Using non-standard ports evades typical port-filtering; repeated connections to atypical ports from network equipment warrants investigation. | **\*\*Medium\*\*** | See Cyclops Blink malware analysis report - list of non-standard C2 ports. |

| **\*\*T1041\*\*** | Large outbound data transfers to a known C2 IP that do not match normal device backup or update patterns. | NetFlow/Zeek volume statistics, proxy transfer logs, or firewall byte-count logs. | The ability to exfiltrate files is part of the malware's C2 capabilities; bulk data pushes to C2 endpoints deviate from normal

```

device behavior. | **Medium** | See Cyclops Blink malware analysis report - typical
exfiltration sizes and destinations. |

TELEMETRY REQUIREMENTS

[] Log source (event type) – needed for – technique IDs and what it detects
[] WatchGuard firewall logs (management-interface connection events) – needed
for – **T1133** (inbound remote-management exploitation)
[] WatchGuard firewall/NetFlow logs (outbound connection metadata) – needed
for – **T1082**, **T1008**, **T1571**, **T1041** (beacon timing, fallback-channel
switching, non-standard ports, exfiltration volume)
[] DNS query logs – needed for – **T1082**, **T1071.001** (domain resolution for
C2, Tor hidden-service lookup)
[] Proxy server access logs (Squid/Bluecoat) – needed for – **T1090**,
T1132.002, **T1071.001**, **T1573.002**, **T1041** (proxy usage, payload
inspection, TLS handshake, large transfers)
[] TLS handshake / certificate logs (firewall or proxy) – needed for –
T1573.002, **T1071.001** (certificate fields, SNI, self-signed cert detection)
[] Zeek/NetFlow L7 payload logs (binary entropy, HTTP(S) body) – needed for –
T1132.002 (non-standard encoding detection)
[] WatchGuard syslog (device-level audit messages) – needed for – **T1133**
(optional context on management-interface events) |

High-value telemetry (enabling multiple techniques):
- **WatchGuard firewall logs** - cover inbound remote-management (T1133), outbound
beaconing (T1082), fallback-channel switching (T1008), non-standard ports (T1571), and
exfiltration volume (T1041).
- **Proxy logs + TLS handshake logs** - together support proxy usage (T1090), web-
protocol C2 (T1071.001), encrypted-channel detection (T1573.002), and payload-encoding
analysis (T1132.002).
- **NetFlow/Zeek flow data** - provide the backbone for timing, IP/port rotation, and
volume-based exfiltration across many C2 techniques.

```

## Iterative Verfeinerung

Verwenden Sie nach der ersten Ausgabe weitere Eingabeaufforderungen, um den Plan zu erweitern oder anzupassen.

- Erweitern Sie den Plan:
  - „Eine Zusammenfassung hinzufügen“

- „Leitlinien zur Reaktion und Eindämmung hinzufügen“
- „Schreiben Sie Erkennungsabfragen für [SIEM-Plattform]“
- Verfeinern Sie basierend auf Ihrer Umgebung:
  - „Wir haben keine DNS-Protokollierung, entfernen diese Hypothesen und konzentrieren uns auf Proxy- und Endpunkt-Telemetrie“
  - „Unsere Partnerorganisation betreibt Sentinel. Geben Sie mir die Erkennungen in KQL, damit wir sie teilen können“

Das Modell überarbeitet den Plan auf der Grundlage des aktualisierten Kontextes.

## Überlegungen

Die folgenden Überlegungen gelten für die Verwendung dieser Aufforderung zur Generierung von Suchplänen anhand von Bedrohungsberichten.

- Überprüfen Sie die technischen Kennungen. Große Sprachmodelle können zu ungenauen technischen Spezifikationen führen. Überprüfen Sie diese Werte anhand verlässlicher Quellen, bevor Sie entsprechend handeln.
- Überprüfen Sie die Telemetrieanforderungen anhand Ihrer Umgebung. Das Modell schlägt Protokollquellen vor, die auf den im Bericht beschriebenen Techniken basieren, nicht auf der Telemetriedaten, die Ihr Unternehmen erfasst. Behandeln Sie die Telemetriecheckliste als eine Reihe von zu bewertenden Anforderungen und nicht als eine Bestandsaufnahme der verfügbaren Daten.
- Beurteilen Sie die Qualität des Quellberichts. Der Jagdplan spiegelt den Inhalt des Eingabeberichts wider. Wenn die Quellinformationen unvollständig, ungenau oder mehrdeutig sind, erbt die Ausgabe diese Einschränkungen. Das Modell bestätigt nicht die Genauigkeit des Berichts.
- Verwenden Sie Jagdpläne als Grundlage für die Erkennungstechnik. Jagdpläne sind Hypothesen, die von Analysten validiert, optimiert und operationalisiert werden müssen. Es handelt sich noch nicht um fertige Erkennungsregeln.
- Reduzieren Sie das Risiko einer sofortigen Injektion. Als Eingabe bereitgestellte Bedrohungsberichte können Anweisungen zur Manipulation des Modells enthalten. Behandeln Sie den Bericht als nicht vertrauenswürdige Daten und nicht als vertrauenswürdige Anweisungen. Weitere Informationen finden Sie unter [Prompt Injection](#).

# Code und Problembehebung

Dieses Kapitel enthält Codebeispiele und Anleitungen zur Fehlerbehebung, damit Sie effektiv mit Amazon Nova-Modellen arbeiten können.

## Code-Bibliothek

Dieser Abschnitt enthält Codebeispiele für gängige Amazon Nova-Operationen, die entweder die Converse API oder die InvokeModel API verwenden.

## Beispiele für die Converse API

### Grundlegende Anfrage

Senden Sie mithilfe der Converse-API eine einfache Textanfrage an Amazon Nova-Modelle.

### Non-streaming

```
import boto3
from botocore.config import Config

Create the Bedrock Runtime client, using an extended timeout configuration
to support long-running requests.
bedrock = boto3.client(
 "bedrock-runtime",
 region_name="us-east-1",
 config=Config(read_timeout=3600),
)

Invoke the model
response = bedrock.converse(
 modelId="us.amazon.nova-2-lite-v1:0",
 messages=[
 {
 "role": "user",
 "content": [{"text": "Write a short story. End the story with 'THE
END'. "}],
 }
],
 system=[{"text": "You are a children's book author."}], # Optional
```

```

inferenceConfig={ # These parameters are optional
 "maxTokens": 1500,
 "temperature": 0.7,
 "topP": 0.9,
 "stopSequences": ["THE END"],
},
additionalModelRequestFields={ # These parameters are optional
 "inferenceConfig": {
 "topK": 50,
 }
},
)

Extract the text response
content_list = response["output"]["message"]["content"]
for content in content_list:
 if "text" in content:
 print(content["text"])

```

## Streaming

```

import boto3
from botocore.config import Config

Create the Bedrock Runtime client, using an extended timeout configuration
to support long-running requests.
bedrock = boto3.client(
 "bedrock-runtime",
 region_name="us-east-1",
 config=Config(connect_timeout=3600, read_timeout=3600),
)

Invoke the model
response = bedrock.converse_stream(
 modelId="us.amazon.nova-2-lite-v1:0",
 messages=[
 {
 "role": "user",
 "content": [{"text": "Write a short story. End the story with 'THE
END'."}],
 }
],
 system=[{"text": "You are a children's book author."}], # Optional

```

```

inferenceConfig={ # These parameters are optional
 "maxTokens": 1500,
 "temperature": 0.7,
 "topP": 0.9,
 "stopSequences": ["THE END"],
},
additionalModelRequestFields={ # These parameters are optional
 "inferenceConfig": {
 "topK": 50,
 }
},
)

Handle streaming events
for event in response["stream"]:
 if "contentBlockDelta" in event:
 delta = event["contentBlockDelta"]["delta"]
 if "text" in delta:
 print(delta["text"], end="", flush=True)

```

## Multimodale Eingabe mit eingebettetem Asset

Verarbeiten Sie multimodale Inhalte, indem Sie Dokument-, Bild-, Video- oder Audiodaten direkt in die Anfrage einbetten. In diesem Beispiel werden Bilddaten verwendet. Einzelheiten zur Inhaltsstruktur für andere Modalitäten finden Sie [in der ContentBlock Amazon Bedrock API-Dokumentation](#).

### Non-streaming

```

import boto3
from botocore.config import Config

Read a document, image, video, or audio file
with open("sample_image.png", "rb") as image_file:
 binary_data = image_file.read()
 data_format = "png"

Define message with image
messages = [
 {
 "role": "user",
 "content": [
 {

```



```

 "image": {
 "format": data_format,
 "source": {
 "bytes": binary_data # For Invoke API, encode as Base64
string
 },
 },
 },
 {"text": "Provide a brief caption for this asset."},
],
}
]

Create the Bedrock Runtime client, using an extended timeout configuration
to support long-running requests.
bedrock = boto3.client(
 "bedrock-runtime",
 region_name="us-east-1",
 config=Config(read_timeout=3600),
)

Invoke model
response = bedrock.converse(
 modelId="us.amazon.nova-2-lite-v1:0",
 messages=messages,
)

Extract the text response
content_list = response["output"]["message"]["content"]
for content in content_list:
 if "text" in content:
 print(content["text"])

```

## Streaming

```

import boto3
from botocore.config import Config

Read a document, image, video, or audio file
with open("sample_image.png", "rb") as image_file:
 binary_data = image_file.read()
 data_format = "png"

```

```

Define message with image
messages = [
 {
 "role": "user",
 "content": [
 {
 "image": {
 "format": data_format,
 "source": {
 "bytes": binary_data # For Invoke API, encode as Base64
string
 },
 },
],
 {"text": "Provide a brief caption for this asset."},
],
 }
]

Create the Bedrock Runtime client, using an extended timeout configuration
to support long-running requests.
bedrock = boto3.client(
 "bedrock-runtime",
 region_name="us-east-1",
 config=Config(connect_timeout=3600, read_timeout=3600),
)

Invoke model with streaming
response = bedrock.converse_stream(
 modelId="us.amazon.nova-2-lite-v1:0",
 messages=messages,
)

Handle streaming events
for event in response["stream"]:
 if "contentBlockDelta" in event:
 delta = event["contentBlockDelta"]["delta"]
 if "text" in delta:
 print(delta["text"], end="", flush=True)

```

## Multimodale Eingabe mit S3-URI

Verarbeiten Sie multimodale Inhalte, indem Sie auf Dokumente, Bilder, Videos oder Audiodateien verweisen, die in S3 gespeichert sind. In diesem Beispiel wird eine Bildreferenz verwendet.

Einzelheiten zur Inhaltsstruktur für andere Modalitäten finden Sie [in der ContentBlock Amazon Bedrock API-Dokumentation](#).

### Non-streaming

```
import boto3
from botocore.config import Config

Define message with image
messages = [
 {
 "role": "user",
 "content": [
 {
 "image": {
 "format": "png",
 "source": {
 "s3Location": {
 "uri": "s3://path/to/your/asset",
 # "bucketOwner": "<account_id>" # Optional
 }
 },
 },
 },
 {"text": "Provide a brief caption for this asset."},
],
 }
]

Create the Bedrock Runtime client, using an extended timeout configuration
to support long-running requests.
bedrock = boto3.client(
 "bedrock-runtime",
 region_name="us-east-1",
 config=Config(read_timeout=3600),
)

Invoke model
response = bedrock.converse(
```

```

 modelId="us.amazon.nova-2-lite-v1:0",
 messages=messages,
)

Extract the text response
content_list = response["output"]["message"]["content"]
for content in content_list:
 if "text" in content:
 print(content["text"])

```

## Streaming

```

import boto3
from botocore.config import Config

Define message with image
messages = [
 {
 "role": "user",
 "content": [
 {
 "image": {
 "format": "png",
 "source": {
 "s3Location": {
 "uri": "s3://path/to/your/asset",
 # "bucketOwner": "<account_id>" # Optional
 }
 },
 },
 },
 {"text": "Provide a brief caption for this asset."},
],
 }
]

Create the Bedrock Runtime client, using an extended timeout configuration
to support long-running requests.
bedrock = boto3.client(
 "bedrock-runtime",
 region_name="us-east-1",
 config=Config(connect_timeout=3600, read_timeout=3600),
)

```

```
Invoke model with streaming
response = bedrock.converse_stream(
 modelId="us.amazon.nova-2-lite-v1:0",
 messages=messages,
)

Handle streaming events
for event in response["stream"]:
 if "contentBlockDelta" in event:
 delta = event["contentBlockDelta"]["delta"]
 if "text" in delta:
 print(delta["text"], end="", flush=True)
```

## Erweitertes Denken (Argumentieren)

Ermöglichen Sie erweitertes Denken für komplexe Problemlösungsaufgaben.

### Non-streaming

```
import boto3
from botocore.config import Config

Create the Bedrock Runtime client, using an extended timeout configuration
to support long-running requests.
bedrock = boto3.client(
 "bedrock-runtime",
 region_name="us-east-1",
 config=Config(read_timeout=3600),
)

Invoke the model
response = bedrock.converse(
 modelId="us.amazon.nova-2-lite-v1:0",
 messages=[
 {
 "role": "user",
 "content": [
 {
 "text": 'How many capital letters appear in the following
passage. Your response must include only the number: "Wilfred ordered an anvil from
ACME. Shipping was expensive."'
 }
]
 }
]
)
```

```

 }
],
}
],
additionalModelRequestFields={
 "reasoningConfig": {
 "type": "enabled",
 "maxReasoningEffort": "low", # "low" | "medium" | "high"
 }
},
)

Extract response content
content_list = response["output"]["message"]["content"]
for content in content_list:
 # Extract the reasoning response
 if "reasoningContent" in content:
 print("\n== Reasoning ==")
 print(content["reasoningContent"]["reasoningText"]["text"])
 # Extract the text response
 if "text" in content:
 print("\n== Text ==")
 print(content["text"])

```

## Streaming

```

import boto3
from botocore.config import Config

Create the Bedrock Runtime client, using an extended timeout configuration
to support long-running requests.
bedrock = boto3.client(
 "bedrock-runtime",
 region_name="us-east-1",
 config=Config(connect_timeout=3600, read_timeout=3600),
)

Invoke the model
response = bedrock.converse_stream(
 modelId="us.amazon.nova-2-lite-v1:0",
 messages=[
 {
 "role": "user",

```

```

 "content": [
 {
 "text": 'How many capital letters appear in the following
passage. Your response must include only the number: "Wilfred ordered an anvil from
ACME. Shipping was expensive."'
 }
],
 },
 additionalModelRequestFields={
 "reasoningConfig": {
 "type": "enabled",
 "maxReasoningEffort": "low", # "low" | "medium" | "high"
 },
 },
)

Process the streaming response
reasoning_output = ""
text_output = ""
for event in response["stream"]:
 if "contentBlockDelta" in event:
 delta = event["contentBlockDelta"]["delta"]

 if "reasoningContent" in delta:
 if len(reasoning_output) == 0:
 print("\n\n== Reasoning ==")
 reasoning_text_chunk = delta["reasoningContent"]["text"]
 print(reasoning_text_chunk, end="", flush=True)
 reasoning_output += reasoning_text_chunk

 elif "text" in delta:
 if len(text_output) == 0:
 print("\n\n== Text ==")
 text_chunk = delta["text"]
 print(text_chunk, end="", flush=True)
 text_output += text_chunk

```

## Integriertes Tool: Nova Grounding mit Zitaten

Verwenden Sie Nova Grounding, um mithilfe von Zitaten Echtzeitinformationen aus dem Internet abzurufen.

## Non-streaming

```
import boto3
from botocore.config import Config

Define the list of tools the model may use
tool_config = {"tools": [{"systemTool": {"name": "nova_grounding"}}]}

Create the Bedrock Runtime client, using an extended timeout configuration
to support long-running requests.
bedrock = boto3.client(
 "bedrock-runtime",
 region_name="us-east-1",
 config=Config(read_timeout=3600),
)

messages = [
 {
 "role": "user",
 "content": [
 {"text": "What is the latest news about renewable energy sources?"}
],
 }
]

Invoke the model
response = bedrock.converse(
 modelId="us.amazon.nova-2-lite-v1:0", messages=messages, toolConfig=tool_config
)

Extract the text with interleaved citations
output_with_citations = ""
content_list = response["output"]["message"]["content"]
for content in content_list:
 if "text" in content:
 output_with_citations += content["text"]

 elif "citationsContent" in content:
 citations = content["citationsContent"]["citations"]
 for citation in citations:
 url = citation["location"]["web"]["url"]
 output_with_citations += f"[{url}]"
```



```
print(output_with_citations)
```

## Streaming

```
import boto3
from botocore.config import Config

Define the list of tools the model may use
tool_config = {"tools": [{"systemTool": {"name": "nova_grounding"}}]}

Create the Bedrock Runtime client, using an extended timeout configuration
to support long-running requests.
bedrock = boto3.client(
 "bedrock-runtime",
 region_name="us-east-1",
 config=Config(read_timeout=3600),
)

messages = [
 {
 "role": "user",
 "content": [
 {"text": "What is the latest news about renewable energy sources?"}
],
 }
]

Invoke the model with streaming
response = bedrock.converse_stream(
 modelId="us.amazon.nova-2-lite-v1:0", messages=messages, toolConfig=tool_config
)

Process the streaming response with interleaved citations
for event in response["stream"]:
 if "contentBlockDelta" in event:
 delta = event["contentBlockDelta"]["delta"]

 if "text" in delta:
 print(delta["text"], end="", flush=True)

 elif "citation" in delta:
 url = delta["citation"]["location"]["web"]["url"]
 print(f"[{url}]", end="", flush=True)
```

## Integriertes Tool: Code Interpreter

Verwenden Sie das Tool Code Interpreter, um Python-Code für Berechnungen und Datenanalysen auszuführen.

### Non-streaming

```
import boto3
from botocore.config import Config

Define the list of tools the model may use
tool_config = {"tools": [{"systemTool": {"name": "nova_code_interpreter"}}]}

Create the Bedrock Runtime client, using an extended timeout configuration
to support long-running requests.
bedrock = boto3.client(
 "bedrock-runtime",
 region_name="us-east-1",
 config=Config(read_timeout=3600),
)

messages = [
 {
 "role": "user",
 "content": [
 {
 "text": "What is the average of 10, 24, 2, 3, 43, 52, 13, 68, 6, 7, 902, 82?"
 }
],
 }
]

Invoke the model
response = bedrock.converse(
 modelId="us.amazon.nova-2-lite-v1:0", messages=messages, toolConfig=tool_config
)

Extract the text and the code the was executed
content_list = response["output"]["message"]["content"]
for content in content_list:
 if "text" in content:
 print("\n== Text ==")
```

```

 print(content["text"])

 elif "toolUse" in content and content["toolUse"]["name"] ==
 "nova_code_interpreter":
 print("\n== Code Interpreter: input.snippet ==")
 print(content["toolUse"]["input"]["snippet"])

```

## Streaming

```

import boto3
from botocore.config import Config
import json

Define the list of tools the model may use
tool_config = {"tools": [{"systemTool": {"name": "nova_code_interpreter"}}]}

messages = [
 {
 "role": "user",
 "content": [
 {
 "text": "What is the average of 10, 24, 2, 3, 43, 52, 13, 68, 6, 7,
902, 82?"
 }
],
 }
]

Create the Bedrock Runtime client, using an extended timeout configuration
to support long-running requests.
bedrock = boto3.client(
 "bedrock-runtime",
 region_name="us-east-1",
 config=Config(connect_timeout=3600, read_timeout=3600),
)

Invoke the model with streaming
response = bedrock.converse_stream(
 modelId="us.amazon.nova-2-lite-v1:0", messages=messages, toolConfig=tool_config
)

Process the streaming response
current_block_start = None

```

```

response_text = ""
for event in response["stream"]:
 if "contentBlockStart" in event:
 current_block_start = event["contentBlockStart"]["start"]

 elif "contentBlockStop" in event:
 current_block_start = None

 elif "contentBlockDelta" in event:
 delta = event["contentBlockDelta"]["delta"]

 if (
 current_block_start
 and "toolUse" in current_block_start
 and current_block_start["toolUse"]["name"] == "nova_code_interpreter"
):
 # This is code interpreter content
 tool_input = json.loads(delta["toolUse"]["input"])
 print("\n== Executed Code Snippet ==")
 print(tool_input["snippet"], end="", flush=True)

 elif "text" in delta:
 # This is text response content
 if len(response_text) == 0:
 print("\n== Text ==")
 text = delta["text"]
 response_text += text
 print(text, end="", flush=True)

```

## Verwendung des Tools

Definieren Sie benutzerdefinierte Tools für das Modell, die während der Konversation verwendet werden sollen.

### Non-streaming

```

import boto3
from botocore.config import Config

def get_weather(city):
 # Mock function to simulate weather API

```

```

 return {"temperatureF": 48, "conditions": "light rain"}

Define the toolSpec for the weather tool
weather_tool = {
 "toolSpec": {
 "name": "get_weather",
 "description": "Get the current weather conditions in a given location",
 "inputSchema": {
 "json": {
 "type": "object",
 "properties": {
 "city": {
 "type": "string",
 "description": "The city and state, e.g. San Francisco, CA",
 }
 },
 "required": ["city"],
 }
 },
 }
}

Define the list of tools the model may use
tool_config = {"tools": [weather_tool]}

Create the Bedrock Runtime client, using an extended timeout configuration
to support long-running requests.
bedrock = boto3.client(
 "bedrock-runtime",
 region_name="us-east-1",
 config=Config(read_timeout=3600),
)

Start tracking message history
messages = []

messages.append(
 {
 "role": "user",
 "content": [
 {
 "text": "Suggest some activities to do in Seattle based on the
current weather."

```

```

 },
],
}
)

Invoke the model
response = bedrock.converse(
 modelId="us.amazon.nova-2-lite-v1:0", messages=messages, toolConfig=tool_config
)

assistant_message = response["output"]["message"]

Add the assistant response to the message history
messages.append(assistant_message)

content_list = assistant_message["content"]
stop_reason = response["stopReason"]

if stop_reason == "tool_use":
 # Extract the toolUse details
 tool_use = next(
 content["toolUse"] for content in content_list if "toolUse" in content
)
 tool_name = tool_use["name"]
 tool_use_id = tool_use["toolUseId"]

 if tool_name == "get_weather":
 # Call the tool
 weather = get_weather(tool_use["input"]["city"])

 # Send the result back to the model
 messages.append(
 {
 "role": "user",
 "content": [
 {
 "toolResult": {
 "toolUseId": tool_use_id,
 "content": [{"json": weather}],
 }
 }
],
 }
)

```

```

Submit the tool result back to the model
response = bedrock.converse(
 modelId="us.amazon.nova-2-lite-v1:0",
 messages=messages,
 toolConfig=tool_config,
)

content_list = response["output"]["message"]["content"]
for content in content_list:
 # Extract the text response
 if "text" in content:
 print("\n== Text ==")
 print(content["text"])
else:
 # A tool call was not needed
 for content in content_list:
 # Extract the text response
 if "text" in content:
 print("\n== Text ==")
 print(content["text"])

```

## Streaming

```

import boto3
from botocore.config import Config
import json

def get_weather(city):
 # Mock function to simulate weather API
 return {"temperatureF": 48, "conditions": "light rain"}

Define the toolSpec for the weather tool
weather_tool = {
 "toolSpec": {
 "name": "get_weather",
 "description": "Get the current weather conditions in a given location",
 "inputSchema": {
 "json": {
 "type": "object",
 "properties": {

```

```

 "city": {
 "type": "string",
 "description": "The city and state, e.g. San Francisco, CA",
 },
 "required": ["city"],
 },
}

Define the list of tools the model may use
tool_config = {"tools": [weather_tool]}

Create the Bedrock Runtime client, using an extended timeout configuration
to support long-running requests.
bedrock = boto3.client(
 "bedrock-runtime",
 region_name="us-east-1",
 config=Config(read_timeout=3600),
)

Start tracking message history
messages = []

messages.append(
 {
 "role": "user",
 "content": [
 {
 "text": "Suggest some activities to do in Seattle based on the
current weather."
 }
],
 }
)

Invoke the model with streaming
response = bedrock.converse_stream(
 modelId="us.amazon.nova-2-lite-v1:0", messages=messages, toolConfig=tool_config
)

Process the streaming response
assistant_message = {"role": "assistant", "content": []}

```



```

current_tool_use = None
stop_reason = None

for event in response["stream"]:
 if "contentBlockStart" in event:
 start = event["contentBlockStart"]["start"]
 if "toolUse" in start:
 current_tool_use = start["toolUse"]
 current_tool_use["input"] = ""

 elif "contentBlockDelta" in event:
 delta = event["contentBlockDelta"]["delta"]
 if "toolUse" in delta:
 current_tool_use["input"] += delta["toolUse"]["input"]
 elif "text" in delta:
 print(delta["text"], end="", flush=True)

 elif "contentBlockStop" in event:
 if current_tool_use:
 # Parse the accumulated tool input
 current_tool_use["input"] = json.loads(current_tool_use["input"])
 assistant_message["content"].append({"toolUse": current_tool_use})
 current_tool_use = None

 elif "messageStop" in event:
 stop_reason = event["messageStop"]["stopReason"]
 if stop_reason == "end_turn":
 exit

Add the assistant response to the message history
messages.append(assistant_message)

if stop_reason == "tool_use":
 # Extract the toolUse details
 tool_use = next(
 content["toolUse"]
 for content in assistant_message["content"]
 if "toolUse" in content
)
 tool_name = tool_use["name"]
 tool_use_id = tool_use["toolUseId"]

 if tool_name == "get_weather":
 # Call the tool

```

```

weather = get_weather(tool_use["input"]["city"])

Send the result back to the model
messages.append(
 {
 "role": "user",
 "content": [
 {
 "toolResult": {
 "toolUseId": tool_use_id,
 "content": [{"json": weather}],
 }
 }
],
 }
)

Submit the tool result back to the model with streaming
response = bedrock.converse_stream(
 modelId="us.amazon.nova-2-lite-v1:0",
 messages=messages,
 toolConfig=tool_config,
)

Handle the final streaming response
print("\n== Text ==")
for event in response["stream"]:
 if "contentBlockDelta" in event:
 delta = event["contentBlockDelta"]["delta"]
 if "text" in delta:
 print(delta["text"], end="", flush=True)

```

## InvokeModel API-Beispiele

Die folgenden Beispiele konzentrieren sich auf die wenigen Schlüsselbereiche, in denen sich die Anfrage- und Antwortstrukturen der Invoke-API geringfügig von denen der Converse-API unterscheiden. In den meisten anderen Bereichen APIs sind die beiden kompatibel, sodass Sie die obigen Beispiele für die Converse-API problemlos an die API anpassen können sollten. InvokeModel

### Grundlegende Anfrage

Senden Sie mithilfe der InvokeModel API eine einfache Textanfrage an Amazon Nova 2-Modelle.

## Non-streaming

```
import json

import boto3
from botocore.config import Config

Configure the request
request_body = {
 "messages": [
 {
 "role": "user",
 "content": [{"text": "Write a short story. End the story with 'THE
END'. "}],
 }
],
 "system": [{"text": "You are a children's book author."}], # Optional
 "inferenceConfig": { # These parameters are optional
 "maxTokens": 1500,
 "temperature": 0.7,
 "topP": 0.9,
 "topK": 50,
 "stopSequences": ["THE END"],
 },
}

bedrock = boto3.client(
 "bedrock-runtime",
 region_name="us-east-1",
 config=Config(read_timeout=3600),
)

Invoke the model
response = bedrock.invoke_model(
 modelId="us.amazon.nova-2-lite-v1:0", body=json.dumps(request_body)
)
response_body = json.loads(response["body"].read())

Extract the text response
content_list = response_body["output"]["message"]["content"]
for content in content_list:
 if "text" in content:
 print(content["text"])
```

## Streaming

```
import json

import boto3
from botocore.config import Config

Configure the request
request_body = {
 "messages": [
 {
 "role": "user",
 "content": [{"text": "Write a short story. End the story with 'THE
END'. "}],
 }
],
 "system": [{"text": "You are a children's book author."}], # Optional
 "inferenceConfig": { # These parameters are optional
 "maxTokens": 1500,
 "temperature": 0.7,
 "topP": 0.9,
 "topK": 50,
 "stopSequences": ["THE END"],
 },
}

bedrock = boto3.client(
 "bedrock-runtime",
 region_name="us-east-1",
 config=Config(connect_timeout=3600, read_timeout=3600),
)

Invoke the model with streaming
response = bedrock.invoke_model_with_response_stream(
 modelId="us.amazon.nova-2-lite-v1:0", body=json.dumps(request_body)
)

Process the streaming response
for event in response["body"]:
 chunk = json.loads(event["chunk"]["bytes"])
 if "contentBlockDelta" in chunk:
 delta = chunk["contentBlockDelta"]["delta"]
 if "text" in delta:
```

```
print(delta["text"], end="", flush=True)
```

## InvokeModel API mit Argumentation

Verwenden Sie die InvokeModel API mit aktivierter Argumentation zur Lösung komplexer Probleme.

### Non-streaming

```
import json

import boto3
from botocore.config import Config

Configure the request
request_body = {
 "messages": [
 {
 "role": "user",
 "content": [
 {
 "text": 'How many capital letters appear in the following
passage. Your response must include only the number: "Wilfred ordered an anvil from
ACME. Shipping was expensive."'
 }
],
 }
],
 "reasoningConfig": {
 "type": "enabled",
 "maxReasoningEffort": "low", # "low" | "medium" | "high"
 },
}

bedrock = boto3.client(
 "bedrock-runtime",
 region_name="us-east-1",
 config=Config(read_timeout=3600),
)

Invoke the model
response = bedrock.invoke_model(
 modelId="us.amazon.nova-2-lite-v1:0", body=json.dumps(request_body)
```

```

)
response_body = json.loads(response["body"].read())

Extract response content
content_list = response_body["output"]["message"]["content"]
for content in content_list:
 # Extract the reasoning response
 if "reasoningContent" in content:
 print("\n== Reasoning ==")
 print(content["reasoningContent"]["reasoningText"]["text"])
 # Extract the text response
 if "text" in content:
 print("\n== Text ==")
 print(content["text"])

```

## Streaming

```

import json

import boto3
from botocore.config import Config

Configure the request
request_body = {
 "messages": [
 {
 "role": "user",
 "content": [
 {
 "text": 'How many capital letters appear in the following
passage. Your response must include only the number: "Wilfred ordered an anvil from
ACME. Shipping was expensive."'
 }
],
 }
],
 "reasoningConfig": {
 "type": "enabled",
 "maxReasoningEffort": "low", # "low" | "medium" | "high"
 },
}

bedrock = boto3.client(

```

```
"bedrock-runtime",
region_name="us-east-1",
config=Config(connect_timeout=3600, read_timeout=3600),
)

Invoke the model with streaming
response = bedrock.invoke_model_with_response_stream(
 modelId="us.amazon.nova-2-lite-v1:0", body=json.dumps(request_body)
)

Process the streaming response
for event in response["body"]:
 chunk = json.loads(event["chunk"]["bytes"])

 if "contentBlockDelta" in chunk:
 delta = chunk["contentBlockDelta"]["delta"]

 # Extract the reasoning response
 if "reasoningContent" in delta:
 print("\n== Reasoning ==")
 print(delta["reasoningContent"]["reasoningText"]["text"], end="",
flush=True)

 # Extract the text response
 if "text" in delta:
 print("\n== Text ==")
 print(delta["text"], end="", flush=True)
```

## Fehlerbehebung

Dieser Abschnitt bietet Lösungen für häufig auftretende Probleme bei der Arbeit mit Amazon Nova-Modellen.

### Authentifizierung und Einrichtung

#### Fehlende Berechtigungen

Symptome: Zugriff auf Nova-Modelle oder -Funktionen nicht möglich

Lösung:

- Stellen Sie sicher, dass Ihre IAM-Rolle über die entsprechenden AmazonBedrockFullAccess Berechtigungen verfügt
- Fordern Sie über die Amazon Bedrock-Konsole Zugriff auf ein bestimmtes Modell an
- Überprüfen Sie die Berechtigungen für den Modellzugriff und die Verwendung von Tools

## Modellzugriff verweigert

Symptome: Die Anfrage für den Modellzugriff schlägt fehl

Lösung:

- Fordern Sie über die Amazon Bedrock-Konsole Zugriff auf ein bestimmtes Modell an
- Vergewissern Sie sich, dass Ihrem Konto Zugriff auf das angeforderte Modell gewährt wurde
- Prüfen Sie die regionale Verfügbarkeit des Modells

## Probleme mit der regionalen Verfügbarkeit

Symptome: Die Funktion ist in der ausgewählten Region nicht verfügbar

Lösung:

- Web Grounding ist nur in US-Regionen mit US-CRIS-Profilen verfügbar
- Stellen Sie sicher, dass das Modell und die Funktionen in der von Ihnen ausgewählten Region verfügbar sind
- Wechseln Sie bei Bedarf zu einer unterstützten Region

## Timeout-Konfiguration

Symptome: Bei Anfragen wurde das Timeout überschritten, bevor sie abgeschlossen werden

Ursache: Das Standard-Timeout ist für komplexe Operationen zu kurz

Lösung: Konfigurieren Sie erweiterte Timeout-Einstellungen

```
from botocore.config import Config

bedrock = boto3.client(
 'bedrock-runtime',
```



```
region_name='us-east-1',
config=Config(
 read_timeout=3600 # 60 minutes
)
)
```

 Note

Amazon Nova-Inferenzanfragen können bei komplexen Vorgängen bis zu 60 Minuten dauern.

## Probleme mit der API-Antwort

Die Gründe für den Stopp verstehen:

`end_turn`

Normaler Abschluss. Keine Aktion erforderlich.

`max_tokens`

Token-Limit erreicht.

Lösung: Erhöhen Sie `maxTokens` den Parameter in `inferenceConfig`.

`content_filtered`

Der Inhalt verstößt gegen die Richtlinie AWS für verantwortungsvolle KI.

Lösung: Überprüfen und ändern Sie Ihre Eingaben, um sie an die Inhaltsrichtlinien zu halten.

`malformed_model_output`

Ungültiges Ausgabeformat.

Lösung: Überprüfen Sie Ihr Ausgabeschema und Ihre Einschränkungen; stellen Sie sicher, dass das JSON-Schema richtig formatiert ist.

`malformed_tool_use`

Ungültiges Format für den Werkzeugaufruf.

Lösung: Stellen Sie sicher, dass die Werkzeugdefinitionen dem erwarteten Schema entsprechen. Überprüfen Sie, ob die Werkzeugeingabeparameter korrekt formatiert sind.

## service\_unavailable

Der integrierte Tool-Service ist nicht verfügbar.

Lösung: Versuchen Sie die Anfrage nach einer kurzen Verzögerung erneut. Überprüfen Sie das AWS Service-Status-Dashboard.

## invalid\_query

Ungültige Abfrage für das integrierte Tool.

Lösung: Überprüfen Sie das Abfrageformat und die Parameter und stellen Sie sicher, dass die Abfrage die Werkzeuganforderungen erfüllt.

## max\_tool\_invocations

Die Wiederholungsversuche des Tools sind erschöpft.

Lösung: Vereinfachen Sie die Aufgabe oder teilen Sie sie in kleinere Schritte auf; überprüfen Sie die Fehlermeldungen des Tools auf bestimmte Probleme.

# Fehler im Argumentationsmodus

## Verkürzte Antworten mit hohem Argumentationsaufwand

Lösung: Wenn Sie einen hohen Argumentationsaufwand benötigen, deaktivieren Sie die folgenden Parameter: „temperature topP maxToken“. Dadurch kann das Modell optimale Einstellungen für komplexe Denkaufgaben verwenden.

## Unzureichende Tokens zum Argumentieren

Fehler: „MaxTokens ist unzureichend“

Lösung: Automatisch mit erhöhtem Limit wiederholen

```
token_limits = {
 "low": 15000,
 "medium": 30000,
 "high": 50000
}

try:
 response = client.converse(

```

```
modelId="us.amazon.nova-2-lite-v1:0",
messages=messages,
inferenceConfig={
 "maxTokens": token_limits[max_effort]
},
additionalModelRequestFields={
 "reasoningConfig": {
 "type": "enabled",
 "maxReasoningEffort": max_effort
 }
}
)
except Exception as e:
 if "maxTokens is insufficient" in str(e):
 higher_limit = int(token_limits[max_effort] * 1.5)
 # Retry with higher limit
```

## Probleme bei der Verwendung von Tools

### Fehler bei der Schemavalidierung

#### Fehler bei der Validierung des Tool-Schemas

##### Lösung:

- Beschränken Sie JSON-Schemas auf zwei Verschachtelungsebenen, um eine optimale Leistung zu erzielen
- Stellen Sie sicher, dass alle erforderlichen Felder richtig definiert sind
- Überprüfen Sie das Schema anhand der JSON-Schemaspezifikation

#### Modell verwendet Tools nicht korrekt

##### Lösung:

- Stellen Sie sicher, dass der Name des Tools seinen Zweck klar beschreibt
- Geben Sie eine detaillierte Beschreibung der Funktionen des Tools an
- Definieren Sie das Eingabeschema explizit mit klaren Parameterbeschreibungen
- Fügen Sie Beispiele in die Beschreibung ein, wenn dies hilfreich ist

#### Inkonsistentes Verhalten beim Aufrufen von Tools

Lösung: Stellen Sie die Temperatur für den Werkzeugaufruf auf 0 ein:

```
inferenceConfig={
 "temperature": 0,
 "maxTokens": 10000
}
```

Dies ermöglicht eine Greed-Dekodierung für eine zuverlässigere Verwendung von Tools.

## Konflikte bei der Werkzeugauswahl

Problem: Fehler bei der Verwendung von benutzerdefinierten Tools mit Websuche oder Codeinterpreter

Lösung: Fügen Sie keine benutzerdefinierte ToolSpec mit Namen hinzu nova\_grounding — dies steht in Konflikt mit dem Systemtool. Verwenden Sie stattdessen die Systemtool-Konfiguration:

```
Correct - use system tool
tool_config = {
 "tools": [{
 "systemTool": {"name": "nova_grounding"}
 }]
}

Incorrect - don't create custom tool with this name
tool_config = {
"tools": [{
"toolSpec": {"name": "nova_grounding", ...}
}]
}
```

## Probleme mit dem Web Grounding

### Probleme mit der Zugriffskontrolle

Problem: Web Grounding und Code Interpreter funktionieren nicht

Lösung: Stellen Sie sicher, dass Ihre IAM-Richtlinie Folgendes umfasst:

```
{
 "Statement": [
 {
```

```
"Effect": "Allow",
"Action": ["bedrock:InvokeTool"],
"Resource": ["arn:aws:bedrock::{YOUR_ACCOUNT_ID}:system-tool/
amazon.nova_grounding"]
}
]
}
```

## Probleme mit der Service Control-Richtlinie

Problem: Web Grounding wurde von SCP blockiert

Lösung: Wenn Sie über Service Control-Richtlinien verfügen, die eine `aws:requestedRegion` Bedingung erfüllen, aktualisieren Sie diese, sodass die Web Grounding-Funktionalität in der Region „nicht spezifiziert“ verfügbar ist.

## Einschränkungen bei der Medienverarbeitung

### Schlechtes Verständnis mehrsprachiger Inhalte in Bildern/Videos

Einschränkung: Nova-Modelle haben nur ein begrenztes Verständnis für mehrsprachige Inhalte in visuellen Medien

Workaround:

- Stellen Sie neben Bildern auch Textübersetzungen zur Verfügung
- Verwenden Sie nach Möglichkeit textbasierte Eingaben für mehrsprachige Inhalte

### Identifizierung von Personen

Problem: Das Modell weigert sich, Personen auf Bildern zu identifizieren

Erwartetes Verhalten: Models werden sich aus Datenschutz- und Sicherheitsgründen weigern, Personen in Bildern, Dokumenten oder Videos zu identifizieren oder zu benennen

Problemumgehung: Fragen Sie nach allgemeinen Merkmalen oder dem Kontext statt nach spezifischen Identitäten

### Einschränkungen des räumlichen Denkens

Problem: Ungenaue Lokalisierungs- oder Layoutanalyse

Einschränkung: Eingeschränkte Fähigkeiten für präzises räumliches Denken

### Workaround:

- Verwenden Sie die Bounding-Box-Erkennung zur Objektlokalisierung
- Geben Sie in Ihren Eingabeaufforderungen klare Referenzpunkte an
- Teilen Sie komplexe räumliche Abfragen in einfachere Komponenten auf

### Kleiner Text in Bildern/Videos

Problem: Kleiner Text in Medien kann nicht gelesen werden

### Lösung:

- Schneiden Sie Bilder so zu, dass sie sich auf relevante Textabschnitte konzentrieren
- Erhöhen Sie die Auflösung der Quellmedien
- Geben Sie den Text separat an, falls verfügbar

## Umgang mit Dokumenten und Dateien

### Nicht unterstützter Inhalt

Problem: Die PDF-Verarbeitung schlägt fehl

### Ursachen:

- PDFs mit CMYK-Farbprofilen
- PDFs enthält SVG-Bilder

### Lösung:

- In PDFs ein RGB-Farbprofil konvertieren
- Rasterisieren Sie SVG-Bilder, bevor Sie sie einfügen PDFs

### Schätzung des Tokens

Problem: Unerwartete Token-Nutzung mit PDFs

Richtlinie: Schätzungsweise etwa 2.560 Token pro Standard-PDF-Seite mit einer Größe von 8,5 × 11 Zoll

Lösung: Passen `maxTokens` Sie das Dokument entsprechend an die Länge des Dokuments an

# API- und SDK-Referenz

Dieser Abschnitt enthält die vollständige technische Referenzdokumentation für Amazon Nova APIs und SDKs.

Themen

- [Anfrage- und Antwortschema](#)
- [SDK-Referenz](#)

## Anfrage- und Antwortschema

Das Anforderungsschema zwischen der Invoke API und der Converse API ist nahezu identisch. Der Hauptunterschied besteht darin, wie Binärdaten (Bilder, Video, Audio) codiert werden: Die Converse-API verwendet binäre Arrays, während die Invoke-API Base64-kodierte Zeichenketten verwendet.

## Vollständige Anforderungsstruktur

Im Folgenden wird die vollständige Anforderungsstruktur für Amazon Nova-Modelle dargestellt. Alle Felder sind optional, sofern sie nicht als erforderlich gekennzeichnet sind:

```
{
 "system": [
 {
 "text": "string"
 }
],
 "messages": [// Required
 {
 "role": "user", // Required - first turn must be user
 "content": [// Required
 {
 "text": "string"
 },
 {
 "image": {
 "format": "jpeg" | "png" | "gif" | "webp", // Required
 "source": { // Required
 "bytes": image // Binary array (Converse) or Base64 string (Invoke)
 }
 }
 }
]
 }
]
}
```

```

 }
 },
 {
 "video": {
 "format": "mkv" | "mov" | "mp4" | "webm" | "three_gp" | "flv" | "mpeg" |
"mpg" | "wmv",
 "source": {
 // Option 1: S3 location
 "s3Location": {
 "uri": "string", // e.g., s3://my-bucket/object-key
 "bucketOwner": "string" // Optional, e.g., "123456789012"
 },
 // Option 2: File bytes
 "bytes": video // Binary array (Converse) or Base64 string (Invoke)
 }
 }
 },
 {
 "audio": { // Nova 2 Omni and Sonic only
 "format": "mp3" | "opus" | "wav" | "aac" | "flac" | "mp4" | "ogg" | "mkv",
 "source": {
 // Option 1: S3 location
 "s3Location": {
 "uri": "string",
 "bucketOwner": "string" // Optional
 },
 // Option 2: File bytes
 "bytes": audio // Binary array (Converse) or Base64 string (Invoke)
 }
 }
 }
],
{
 "role": "assistant",
 "content": [
 {
 "text": "string" // For prefilling assistant response
 }
]
}
],
"inferenceConfig": { // All optional
 "maxTokens": int, // 1-5000, default: dynamic

```



```

 "temperature": float, // 0.00001-1, default: 0.7
 "topP": float, // 0-1, default: 0.9
 "topK": int, // 0-128, default: not used
 "stopSequences": ["string"],
 "reasoningConfig": { // Nova 2 Lite and Sonic only
 "type": "enabled" | "disabled", // default: "disabled"
 "maxReasoningEffort": "low" | "medium" | "high"
 }
 },
 "toolConfig": { // Optional
 "tools": [
 {
 "toolSpec": {
 "name": "string", // Max 64 characters
 "description": "string",
 "inputSchema": {
 "json": {
 "type": "object",
 "properties": {
 "arg1": {
 "type": "string",
 "description": "string"
 }
 }
 },
 "required": ["string"]
 }
 }
 }
]
 },
 "toolChoice": { // Choose one option
 "auto": {},
 "any": {},
 "tool": {
 "name": "string"
 }
 }
}

```

Wichtige Anforderungsparameter:

- **system**: Systemaufforderung mit Kontext und Anweisungen

- `messages`: Reihe von Gesprächsrunden mit Rolle (Benutzer oder Assistent) und Inhalt
- `inferenceConfig`: Steuert das Verhalten der Modellausgabe (Temperatur, Tokens usw.)
- `toolConfig`: Werkzeugspezifikationen für den Funktionsaufruf

#### Note

Wenn Sie die Converse-API verwenden, müssen die `reasoningConfig` Parameter `topK` und `additionalModelRequestFields` anstelle von `inferenceConfig` eingegeben werden.

Die folgenden Abschnitte enthalten detaillierte Erläuterungen zu den einzelnen Anforderungsparametern:

#### `system`

`system` – (Optional) Der System-Prompt für die Anfrage. Eine Systemaufforderung bietet Amazon Nova Kontext und Anweisungen, z. B. die Angabe eines bestimmten Ziels oder einer bestimmten Rolle.

#### `messages`

`messages`— (Erforderlich) Das Eingabe-Nachrichten-Array, das Gesprächsrunden enthält.

- `role`— (Erforderlich) Die Rolle der Konversationsrunde. Gültige Werte sind `user` und `assistant`. Die erste Nachricht muss immer die `user` Rolle verwenden.
- `content`— (Erforderlich) Eine Reihe von Inhaltsblöcken. Jeder Block spezifiziert einen Inhaltstyp (`text`, `image`, `video`, oder `audio`):
  - `text`— Textinhalt für die Konversation. Wird in Kombination mit Bild oder Video als Begleittext interpretiert.
  - `image`— (Nicht unterstützt für Nova 2 Lite) Bildinhalt mit:
    - `format`— (Erforderlich) Bildformat: `jpeg`, `png`, `webp`, oder `gif`
    - `source.bytes`— (Erforderlich) Bilddaten als binäres Array (Converse API) oder Base64-String (Invoke API)
  - `video`— (Nicht unterstützt für Nova 2 Lite) Videoinhalt mit:
    - `format`— (Erforderlich) Videoformat: `mkv`, `mov`, `mp4`, `webm`, `three_gp`, `flv`, `mpeg`, `mpg`, oder `wmv`

- `source`— (Erforderlich) Videoquelle über S3-URI (`s3Location.uri` und `optionalbucketOwner`) oder Dateibytes (bytes)
- `audio`— (Amazon Nova Sonic und nur) Audioinhalte mit:
  - `format`— (Erforderlich) Audioformat: `mp3`, `opus`, `wav`, `aac`, `flac`, `mp4`, `ogg`, oder `mkv`
  - `source`— (Erforderlich) Audioquelle über S3-URI oder Dateibytes

## `inferenceConfig`

`inferenceConfig`— (Optional) Konfigurationsparameter, die die Generierung der Modellausgabe steuern.

- `maxTokens`— (Optional) Maximale Anzahl an Tokens, die vor dem Stoppen generiert werden müssen. Amazon Nova-Modelle werden möglicherweise gestoppt, bevor dieses Limit erreicht wird. Der Höchstwert ist 5.000. Wenn nicht angegeben, wird ein dynamischer Standard verwendet, der auf dem Anforderungskontext basiert.
- `temperature`— (Optional) Zufälligkeit der Antworten. Gültiger Bereich: 0,00001-1 (Standard: 0,7). Niedrigere Werte führen zu einer deterministischeren Ausgabe.
- `topP`— (Optional) Schwellenwert für die Nukleus-Probenahme. Amazon Nova nimmt Stichproben von Tokens, deren kumulative Wahrscheinlichkeit erreicht `topP`. Gültiger Bereich: 0-1 (Standard: 0,9). Passen Sie entweder `temperature` oder `topP`, nicht beide an.
- `topK`— (Optional) Nur Probe aus den Top K Tokens. Entfernt Antworten mit geringer Wahrscheinlichkeit. Gültiger Bereich: 0-128 (Standard: nicht verwendet).

### Note

Geben Sie für die Converse API ein. `topK` `additionalModelRequestFields`

- `stopSequences`— (Optional) Array von Zeichenketten, deren Generierung beendet wird, wenn sie gefunden wird.
- `reasoningConfig`— (Amazon Nova Sonic und nur) Konfiguration von Reasoning:
  - `type`— (Optional) `enabled` oder `disabled` (Standard: `disabled`)
  - `maxReasoningEffort`— Rechenaufwand: `low`, `medium`, oder `high`. Mit `low` und wird das `medium` Argumentieren inkrementell gestreamt; `high` gibt die Argumentation in einem letzten Abschnitt aus.

 Note

Geben Sie für die Converse API ein. `reasoningConfig`  
`additionalModelRequestFields`

## toolConfig

`toolConfig`— (Optional) Konfiguration des Tools nach dem [ToolConfiguration Schema](#).

- `tools`— Reihe von Werkzeugspezifikationen mit `name`, `description` und `inputSchema`
- `toolChoice`— (Optional) Steuert die Werkzeugauswahl:
  - `auto`— Das Modell entscheidet, ob und welche Tools verwendet werden
  - `any`— Das Modell muss mindestens ein Werkzeug verwenden
  - `tool`— Das Modell muss das angegebene Werkzeug namentlich verwenden

## Vollständige Antwortstruktur

Im Folgenden wird die vollständige Antwortstruktur für Amazon Nova-Modelle dargestellt:

```
{
 "ResponseMetadata": {
 "RequestId": "string",
 "HTTPStatusCode": int,
 "HTTPHeaders": {
 "date": "string",
 "content-type": "application/json",
 "content-length": "string",
 "connection": "keep-alive",
 "x-amzn-requestid": "string"
 },
 "RetryAttempts": 0
 },
 "output": {
 "message": {
 "role": "assistant",
 "content": [
 {
 "reasoningContent": { // Optional - if reasoning enabled
```

```

 "reasoningText": {
 "text": "[REDACTED]"
 }
 },
 {
 "toolUse": { // Optional - if tool called
 "toolUseId": "string",
 "name": "string",
 "input": {} // Tool-specific arguments
 }
 },
 {
 "text": "string" // Optional - text response
 },
 {
 "image": { // Optional - Nova 2 Omni only
 "format": "png",
 "source": {
 "bytes": image // Binary array (Converse) or Base64 string (Invoke)
 }
 }
 }
]
}
},
"stopReason": "string", // See stop reasons below
"usage": {
 "inputTokens": int,
 "outputTokens": int,
 "totalTokens": int
},
"metrics": {
 "latencyMs": int
}
}

```

### Gründe für den Stopp:

- `end_turn`: Natürliches Ende der Antwort
- `max_tokens`: Das MaxToken-Limit wurde erreicht
- `content_filtered`: Gegen die Inhaltsrichtlinie verstoßen

- `malformed_model_output`: Ungültige Modellausgabe
- `malformed_tool_use`: Ungültige Ausgabe zur Verwendung des Werkzeugs
- `service_unavailable`: Der integrierte Tool-Service ist nicht erreichbar
- `invalid_query`: Ungültige Abfrage zum integrierten Tool
- `max_tool_invocations`: Die Wiederholungsversuche des Tools sind erschöpft

Die folgenden Abschnitte enthalten ausführliche Erläuterungen zu den einzelnen Antwortfeldern:

## output

`output`— (Erforderlich) Enthält die Antwortnachricht des Modells.

- `message`— (Erforderlich) Die Antwortnachricht des Assistenten mit Rolle und Inhaltsarray.
- `content`— (Erforderlich) Eine Reihe von Inhaltsblöcken, die Folgendes beinhalten können:
  - `reasoningContent`— (Optional) Wird zurückgegeben, wenn Argumentation aktiviert war. Enthält Argumentationstext, der immer [REDACTED] in der Antwort enthalten sein wird.
  - `toolUse`— (Optional) Wird zurückgegeben, wenn ein Tool aufgerufen wurde. Enthält die Verwendungs-ID, den Namen und die Eingabeargumente des Tools.
  - `text`— (Optional) Wird zurückgegeben, wenn das Modell mit Textinhalt geantwortet hat.
  - `image`— (Nur optional) Wird zurückgegeben, wenn das Modell ein Bild generiert hat. Das Format wird immer PNG sein.

## StopReason

`stopReason`— (Erforderlich) Gibt an, warum das Modell keine Ausgabe mehr generiert hat:

- `end_turn`— Natürliches Ende der Antwort erreicht
- `max_tokens`— Das MaxToken-Limit oder das maximale Ausgangslimit des Modells wurde erreicht
- `content_filtered`— Die Ausgabe hat gegen die Richtlinie AWS für verantwortungsvolle KI verstoßen
- `malformed_model_output`— Das Modell hat eine ungültige Ausgabe erzeugt
- `malformed_tool_use`— Das Modell hat eine ungültige Ausgabe für die Werkzeugnutzung erzeugt
- `service_unavailable`— Der integrierte Werkzeugservice konnte nicht erreicht werden
- `invalid_query`— Die Abfrage an das integrierte Tool war ungültig

- `max_tool_invocations`— Das integrierte Tool lieferte nach Wiederholungsversuchen kein gültiges Ergebnis

## Nutzung

`usage`— (Erforderlich) Informationen zur Token-Nutzung:

- `inputTokens`— Gesamtzahl der vom Modell aufgenommenen Token
- `outputTokens`— Anzahl der generierten Token
- `totalTokens`— Summe der Eingabe- und Ausgabetoken

## Metriken

`metrics`— (Erforderliche) Leistungskennzahlen:

- `latencyMs`— Gesamtdauer für die Fertigstellung der Inferenz in Millisekunden

# SDK-Referenz

AWS Software Development Kits (SDKs) sind für viele beliebte Programmiersprachen verfügbar. Jedes SDK bietet eine API, Codebeispiele und Dokumentation, die es Entwicklern erleichtern, Anwendungen in ihrer bevorzugten Sprache zu erstellen.

| SDK-Dokumentation                      | Codebeispiele                                        |
|----------------------------------------|------------------------------------------------------|
| <a href="#">AWS SDK for C++</a>        | <a href="#">AWS SDK for C++ C++-Codebeispiele</a>    |
| <a href="#">AWS CLI</a>                | <a href="#">AWS CLI-Codebeispiele</a>                |
| <a href="#">AWS SDK for Go</a>         | <a href="#">AWS SDK for Go Go-Codebeispiele</a>      |
| <a href="#">AWS SDK für Java</a>       | <a href="#">AWS SDK for Java Java-Codebeispiele</a>  |
| <a href="#">AWS SDK für JavaScript</a> | <a href="#">AWS SDK für JavaScript Codebeispiele</a> |
| <a href="#">AWS SDK für Kotlin</a>     | <a href="#">AWS SDK für Kotlin-Codebeispiele</a>     |
| <a href="#">AWS SDK for .NET</a>       | <a href="#">AWS SDK for .NET .NET-Codebeispiele</a>  |

| SDK-Dokumentation                          | Codebeispiele                                                |
|--------------------------------------------|--------------------------------------------------------------|
| <a href="#">AWS SDK for PHP</a>            | <a href="#">AWS SDK for PHP PHP-Codebeispiele</a>            |
| <a href="#">AWS Tools für PowerShell</a>   | <a href="#">AWS Tools für PowerShell Codebeispiele</a>       |
| <a href="#">AWS SDK for Python (Boto3)</a> | <a href="#">AWS Codebeispiele für SDK for Python (Boto3)</a> |
| <a href="#">AWS SDK for Ruby</a>           | <a href="#">AWS SDK for Ruby Ruby-Codebeispiele</a>          |
| <a href="#">AWS SDK für Rust</a>           | <a href="#">AWS SDK für Rust-Codebeispiele</a>               |
| <a href="#">AWS SDK für SAP ABAP</a>       | <a href="#">AWS SDK für SAP ABAP-Codebeispiele</a>           |
| <a href="#">AWS SDK für Swift</a>          | <a href="#">AWS SDK für Swift-Codebeispiele</a>              |



# Anpassen von Amazon Nova-Modellen auf KI SageMaker

Sie können Amazon Nova-Modelle, einschließlich der erweiterten Amazon Nova 2.0-Modelle, anhand von [Rezepten](#) anpassen und sie anhand von Rezepten trainieren SageMaker. Diese Rezepte unterstützen Techniken wie Supervised Fine-Tuning (SFT) und Reinforcement Fine-Tuning (RFT) mit Optionen für Full-Rank und Low-Rank Adaptation (LoRa).

Der gesamte Anpassungsablauf umfasst Phasen wie das Modelltraining, die Modellbewertung und die Bereitstellung für Inferenz. Dieser Ansatz zur Modellanpassung SageMaker bietet mehr Flexibilität und Kontrolle bei der Feinabstimmung der unterstützten Amazon Nova-Modelle, der präzisen Optimierung von Hyperparametern und der Implementierung von Techniken wie LoRa Parameter-Efficient Fine-Tuning (PEFT), Full-Rank SFT, RFT und Continued (CPT). Pre-Training

## Ansätze zur Anpassung

SageMaker bietet zwei Ansätze für die Anpassung von Amazon Nova-Modellen:

UI-based Erfahrung — Verwenden Sie diese Option, um Amazon Nova-Modelle über eine einfache, geführte Oberfläche anzupassen. Dieser Ansatz bietet einen durchgängigen Workflow, einschließlich Schulung, Evaluierung und Bereitstellung, ohne dass Code geschrieben werden muss. Die UI-based Erfahrung ist ideal für schnelle Experimente, die Entwicklung von Machbarkeitsnachweisen und für Benutzer, die einen visuellen Arbeitsablauf bevorzugen.

Code-based Erfahrung — Verwenden Sie das SageMaker Python SDK, das Nova SDK und Trainingsrezepte, um Modelle programmgesteuert anzupassen. Dieser Ansatz bietet mehr Flexibilität und ermöglicht Ihnen die Konfiguration erweiterter Hyperparameter, die Integration in CI/CD Pipelines und die Automatisierung von Trainingsabläufen. Die codebasierte Erfahrung wird für Produktionsworkloads, komplexe Anpassungsanforderungen und Teams mit etablierten MLOps-Praktiken empfohlen.

| Ansatz     | Am besten geeignet für                                  | Wichtigste Vorteile                                                         |
|------------|---------------------------------------------------------|-----------------------------------------------------------------------------|
| UI-based   | Experimentieren, Prototyping, schnelle Iterationen      | Einfache Einrichtung, geführter Arbeitsablauf, keine Codierung erforderlich |
| Code-based | Produktion, Automatisierung, erweiterte Konfigurationen | Volle Flexibilität, Pipeline-Integration, Versionskontrolle                 |

## Plattformen zur Anpassung

AWS bietet drei Plattformen für die Anpassung von Amazon Nova-Modellen, die jeweils für unterschiedliche Anwendungsfälle und Anforderungen konzipiert sind:

**Amazon Bedrock** — Bietet den einfachsten und schnellsten Weg zur Modellanpassung mit minimalem Einrichtungsaufwand. Bedrock wickelt das gesamte Infrastrukturmanagement automatisch ab, sodass Sie sich auf Ihre Daten und Ihren Anwendungsfall konzentrieren können. Diese Plattform ist ideal, wenn Sie die schnellste Amortisierungszeit benötigen und ein vollständig verwaltetes Erlebnis bevorzugen.

**SageMaker Schulungsjobs** — Bietet eine vollständig verwaltete Umgebung für die Anpassung von Amazon Nova-Modellen, in der Sie keine Cluster erstellen oder verwalten müssen. Der Service kümmert sich automatisch um die gesamte Bereitstellung, Skalierung und Ressourcenverwaltung der Infrastruktur, sodass Sie sich auf die Konfiguration Ihrer Schulungsparameter und die Einreichung Ihres Jobs konzentrieren können. Diese Plattform bietet ein ausgewogenes Verhältnis zwischen Benutzerfreundlichkeit und Flexibilität und unterstützt Techniken wie Parameter Efficient Fine-tuning (PEFT), Full Rank Fine Tuning und Reinforcement Fine-Tuning (RFT).

**SageMaker HyperPod** — Bietet eine spezielle Umgebung für groß angelegte verteilte Schulungen, in der Sie EKS-Cluster mit eingeschränkten Instanzgruppen (RIGs) erstellen und verwalten müssen. Diese Plattform bietet Ihnen maximale Flexibilität bei der Konfiguration Ihrer Schulungsumgebung mit speziellen GPU-Instances und integriertem Amazon FSx for Lustre-Speicher und eignet sich daher besonders für fortgeschrittene verteilte Schulungsszenarien, die laufende Modellentwicklung und kundenspezifische Workloads auf Unternehmensebene.

| Plattform                 | Komplexität    | Flexibilität | Am besten geeignet für                                        |
|---------------------------|----------------|--------------|---------------------------------------------------------------|
| Amazon Bedrock            | Am niedrigsten | Standard     | Schnellste Anpassung, minimaler Einrichtungsaufwand           |
| SageMaker Ausbildungsjobs | Medium         | Hoch         | Ausgewogene Flexibilität und Benutzerfreundlichkeit           |
| SageMaker HyperPod        | Am höchsten    | Maximum      | Umfangreiches, verteiltes Training, Workloads für Unternehmen |

 Note

Wenn Sie einen KMS-Schlüssel für Ihren Schulungsjob zur Anpassung des Amazon Nova-Modells für die Verschlüsselung im Amazon-owned Ausgabe-S3-Bucket angeben:

- Sie müssen denselben KMS-Schlüssel angeben, wenn Sie nachfolgende iterative Trainingsjobs aufrufen oder wenn Sie die Amazon CreateCustomModel Bedrock-API aufrufen, die das verschlüsselte Modell nutzt.
- Die Identität, die die CreateTrainingJob API aufruft (und nicht die Ausführungsrolle), muss über die in der KMS-Schlüsselrichtlinie definierten Berechtigungen für CreateGrant RetireGrantEncrypt,, und GenerateDataKey verfügen.

## Allgemeine Voraussetzungen

Der Anpassungsprozess umfasst mehrere wichtige Phasen, darunter das Training, die Bewertung und die Bereitstellung des Modells zu Inferenzzwecken, für die jeweils spezifische Ressourcen und Konfigurationen erforderlich sind. Bevor Sie mit der Anpassung Ihres Amazon Nova-Modells beginnen SageMaker, stellen Sie sicher, dass Sie die folgenden allgemeinen Voraussetzungen erfüllen.

- Ein AWS-Konto. Wenn Sie noch keine haben AWS-Konto, folgen Sie [diesen Anweisungen](#), um sich für eine anzumelden.
- [Installation der AWS CLI](#) und [Einrichtung der Konfiguration](#)
- Zugriff auf die [Basisrezepte für die Anpassung von Amazon-Nova-Modellen](#)
- Vertrautheit mit [YAML](#)-Konfigurationsdateien
- Vertrautheit mit dem Betrieb eines Notebooks in Ihrer Umgebung
- Vertrautheit mit der Erstellung von AWS Ressourcen wie [Amazon S3 S3-Buckets](#) und [IAM-Rollen mit entsprechenden Berechtigungen](#).
- Vertrautheit mit dem [Trainieren](#) eines Modells. SageMaker
- Vertrautheit [SageMaker HyperPod mit der EKS-Orchestrierung](#).
- Vertrautheit mit [SageMaker HyperPod CLI](#).
- Vertrautheit mit den [Basismodellen von Amazon Nova](#)
- Vertrautheit mit den [verfügbaren Amazon-Nova-Modellen und Algorithmen zur Anpassung](#)
- Vertrautheit mit der [Amazon-Bedrock-Inferenz](#)

# Amazon-Nova-Rezepte

Sie können ein Amazon Nova-Rezept aus dem [Rezepte-Repository](#) abrufen. Ein Amazon Nova-Rezept ist eine [YAML-Konfigurationsdatei](#), die Details SageMaker zur Ausführung Ihres Modellanpassungsjobs enthält. Sie enthält den Namen des Basismodells, legt die Hyperparameter für das Training fest, definiert Feinabstimmungseinstellungen und enthält alle zusätzlichen Optionen, die für die Feinabstimmung oder das erfolgreiche Training des Modells erforderlich sind.

Sie können auch über SageMaker AI Monarch auf Amazon Nova-Rezepte zugreifen, indem Sie zum Model-Hub navigieren, Amazon Nova-Modelle auswählen und durchsuchen AWS, um die zugehörigen Rezepte zu finden. Sowohl SageMaker AI Monarch als auch ich stellen Beispielenotizbücher für jedes Rezept bereit, die alle notwendigen Schritte enthalten, um die Rezepte zu ändern und Anpassungsaufgaben mithilfe von SageMaker Trainingsjobs oder Umgebungen auszuführen. SageMaker HyperPod

Um auf die Rezeptseiten in Amazon SageMaker Studio zugreifen zu können, muss die Ausführungsrolle über die folgenden Berechtigungen verfügen.

JSON

```
{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Effect": "Allow",
 "Action": [
 "s3:GetObject"
],
 "Resource": [
 "arn:aws:s3:::*model-customization-recipes*"
]
 }
]
}
```

Verwenden Sie eine der folgenden SageMaker Distributions-Image-Versionen, um die Beispielenotizbücher für SageMaker Trainingsjobs auszuführen: 2.7.1+2.8.0+,,3.2.1+,3.3.0+. Dies gilt sowohl für SageMaker AI Monarch als auch.

## Themen

- [Abrufen von Amazon-Nova-Rezepten](#)
- [Amazon Nova Forge-Rezepte abrufen](#)
- [Verfügbare Modelle und Algorithmen](#)
- [Amazon Nova 2.0 Lite](#)

## Abrufen von Amazon-Nova-Rezepten

Um ein Amazon Nova-Basisrezept zu erhalten, klonen Sie das [Rezepte-Repository](#), indem Sie den folgenden Befehl ausführen.

```
git clone https://github.com/aws/sagemaker-hyperpod-recipes.git
```

Die Basisrezepte sind unter [recipes\\_collection/recipes/](#) verfügbar.

```
cd recipes_collection/recipes/
```

Die Amazon-Nova-Anpassungsrezepte befinden sich in den folgenden Ordnern.

| Rezepttyp                | Ordner                          |
|--------------------------|---------------------------------|
| SFT (Full-rank und PEFT) | <a href="#">gut-tuning/nova</a> |
| Bewertung                | <a href="#">evaluation/nova</a> |
| CPT                      | <a href="#">training/nova</a>   |

## Amazon Nova Forge-Rezepte abrufen

Um auf spezielle Amazon Nova Forge-Rezepte für Jobs zuzugreifen, [richten Sie bitte Ihren Zugang zu Amazon Nova Forge](#) ein und folgen Sie dann [diesem Workshop](#), um die Forge-Version der CLI einzurichten. Bei SageMaker Trainingsjobs greifen die AWS Konsole und das Nova Forge SDK automatisch auf Forge-Rezepte zu.

## Verfügbare Modelle und Algorithmen

In der folgenden Tabelle werden die Verfügbarkeit von Anpassungen für Amazon Nova-Modelle und die unterstützten Algorithmen unter Verwendung von SageMaker zusammengefasst.

| Modellname           | Modell-ID                         | Fine-tuning | Hinweise                                                                                                                                                                                                                                                                                                                                                                                                                                   |
|----------------------|-----------------------------------|-------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Amazon Nova Lite 2.0 | amazon.nova-2-lite-v<br>1:0:256 k | Ja          | <ul style="list-style-type: none"> <li>• SFT — Akzeptiert entweder Text, and/or Bild oder Textvideo als Eingabe und erzeugt Text als Ausgabe. and/or Ein einzelner Job kann Text, Bild und Video nicht in derselben Ausführung kombinieren.</li> <li>• RFT — Akzeptiert Text und Bild als Eingabe für Single-Turn-Konversationen und erzeugt Text als Ausgabe. Verbesserte Funktionen zur Belohnungsoptimierung.</li> <li>• CPT</li> </ul> |

# Amazon Nova 2.0 Lite

In der folgenden Tabelle sind detaillierte Informationen zur Amazon Nova 2.0 Lite-Rezeptreferenz aufgeführt.

| Modell              | Category/<br>Sub-<br>categ<br>ory                | Technik                                 | Name des Rezepts                                 | Bild-URI<br>(Ausbildu<br>ngsjobs)                                                    | Bild-URI<br>(SageMaker<br>HyperPod)                                                  | Instanz<br>berechnen                 |
|---------------------|--------------------------------------------------|-----------------------------------------|--------------------------------------------------|--------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------|--------------------------------------|
| Nova<br>2.0<br>Lite | Training                                         | Fortsetzu<br>ng des<br>Vortraini<br>ngs | nova_lite<br>_2_0_p5x8<br>_gpu_pret<br>rain.yaml | N/A                                                                                  | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-CPT-V2-latest | ml.p5.48xlarge ,<br>ml.p5en.48xlarge |
| Nova<br>2.0<br>Lite | Paramete<br>effizient<br>e<br>Feinabsti<br>mmung | Feinabsti<br>mmung                      | nova_lite<br>_2_0_p5_g<br>pu_lora_sft.yaml       | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-TJ-SFT-V2-latest | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-S             | ml.p5.48xlarge ,<br>ml.p5en.48xlarge |

| Modell        | Category/<br>Sub-category | Technik        | Name des Rezepts              | Bild-URI<br>(Ausbildungsjobs)                                                        | Bild-URI<br>(SageMaker HyperPod)                                                     | Instanz berechnen                |
|---------------|---------------------------|----------------|-------------------------------|--------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------|----------------------------------|
|               |                           |                |                               |                                                                                      | FT-V2-latest                                                                         |                                  |
| Nova 2.0 Lite | Full-Rank Feinabstimmung  | Feinabstimmung | nova_lite_2_0_p5_gpu_sft.yaml | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-TJ-SFT-V2-latest | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-SFT-V2-latest | m1.p5.48xlarge, m1.p5en.48xlarge |



| Modell        | Category/<br>Sub-category | Technik        | Name des Rezepts                            | Bild-URI<br>(Ausbildungsjobs)                                                        | Bild-URI<br>(SageMaker HyperPod)                                                           | Instanz<br>berechnen             |
|---------------|---------------------------|----------------|---------------------------------------------|--------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------|----------------------------------|
| Nova 2.0 Lite | Parameter effizientes RFT | Feinabstimmung | nova_lite_v2_smtj_p5_p5en_gpu_lora_rft.yaml | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-TJ-RFT-V2-latest | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-RFT-TRAIN-V2-latest | m1.p5.48xlarge, m1.p5en.48xlarge |

| Modell        | Category/<br>Sub-category | Technik        | Name des Rezepts                    | Bild-URI<br>(Ausbildungsjobs)                                                        | Bild-URI<br>(SageMaker HyperPod)                                                           | Instanz berechnen                |
|---------------|---------------------------|----------------|-------------------------------------|--------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------|----------------------------------|
| Nova 2.0 Lite | RFT mit vollem Rang       | Feinabstimmung | nova_lite_v2_smtj_p5en_gpu_rft.yaml | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-TJ-RFT-V2-latest | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-RFT-TRAIN-V2-latest | m1.p5.48xlarge, m1.p5en.48xlarge |

| Mode          | Category/<br>Sub-category          | Technik   | Name des Rezepts                                            | Bild-URI<br>(Ausbildungsjobs)                                                          | Bild-URI<br>(SageMaker HyperPod)                                                       | Instanz berechnen                 |
|---------------|------------------------------------|-----------|-------------------------------------------------------------|----------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------|-----------------------------------|
| Nova 2.0 Lite | Bringen Sie Ihre eigenen Daten mit | Bewertung | nova_lite_2_0_p5_48x1_gpu_bring_your_own_data_set_eval.yaml | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-TJ-Eval-V2-1atest | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-HP-Eval-V2-1atest | ml.p5.48xlarge , ml.p5en.48xlarge |
| Nova 2.0 Lite | Allgemeiner Text-Benchmark         | Bewertung | nova_lite_2_0_p5_48x1_gpu_general_text_benchmark_eval.yaml  | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-TJ-Eval-V2-1atest | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-HP-Eval-V2-1atest | ml.p5.48xlarge , ml.p5en.48xlarge |

| Modell        | Category/<br>Sub-category              | Technik   | Name des Rezepts                                     | Bild-URI<br>(Ausbildungsjobs)                                                          | Bild-URI<br>(SageMaker HyperPod)                                                       | Instanz berechnen                 |
|---------------|----------------------------------------|-----------|------------------------------------------------------|----------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------|-----------------------------------|
| Nova 2.0 Lite | RFT-Bewertung                          | Bewertung | nova_lite_2_0_p5_48x1_gpu_rft_eval.yaml              | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-TJ-Eval-V2-1atest | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-HP-Eval-V2-1atest | ml.p5.48xlarge , ml.p5en.48xlarge |
| Nova 2.0 Lite | LLM-Richter mit rubrikbasierter Rubrik | Bewertung | nova_lite_2_0_p5_48x1_gpu_rubric_llm_judge_eval.yaml | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-TJ-Eval-V2-1atest | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-HP-Eval-V2-1atest | ml.p5.48xlarge , ml.p5en.48xlarge |

# Amazon Nova-Anpassung bei SageMaker Schulungsjobs

SageMaker Training Jobs ist eine Umgebung, in der Sie Modelle für maschinelles Lernen in großem Maßstab trainieren können. Sie stellt Rechenressourcen automatisch bereit und skaliert sie, lädt Trainingsdaten aus Quellen wie Amazon S3, führt Ihren Trainingscode aus und speichert die resultierenden Modellartefakte.

Der Zweck des Trainings besteht darin, das Amazon-Nova-Basismodell anhand Ihrer geschützten Daten anzupassen. Der Trainingsprozess umfasst in der Regel Schritte zur Vorbereitung Ihrer Daten, zur Auswahl eines [Rezepts](#), zur Änderung der Konfigurationsparameter in YAML-Dateien und zum Einreichen eines Trainingsjobs. Der Trainingsprozess gibt den Checkpoint für das trainierte Modell in einem serviceverwalteten Amazon-S3-Bucket aus. Sie können den Speicherort dieses Checkpoints für Bewertungsjobs verwenden. Nova-Anpassungen für SageMaker KI-Schulungsjobs speichern Modellartefakte in einem serviceverwalteten Amazon S3 S3-Bucket. Artefakte im vom Service verwalteten Bucket sind mit SageMaker AI-managed KMS-Schlüsseln verschlüsselt. Service-managed Amazon S3 S3-Buckets unterstützen derzeit keine Datenverschlüsselung mit kundenverwalteten KMS-Schlüsseln.

## Bewährte Methoden für die Anpassung von Amazon Nova

### -Übersicht

Dieser Abschnitt bietet einen Überblick über Anpassungstechniken und hilft Ihnen bei der Auswahl des besten Ansatzes für Ihre Bedürfnisse und verfügbaren Daten.

### Zwei Phasen der LLM-Ausbildung

Das Training mit großen Sprachmodellen besteht aus zwei Hauptphasen: vor dem Training und nach dem Training. Während des Trainings vor dem Training verarbeitet das Modell Tokens mit Rohtext und optimiert es für die Vorhersage des nächsten Tokens. Dieser Prozess erstellt einen Mustervervollständiger, der Syntax, Semantik, Fakten und Argumentationsmuster aus dem Internet und kuratiertem Text aufnimmt. Das vortrainierte Modell versteht jedoch Anweisungen, Benutzerziele oder kontextgerechtes Verhalten nicht. Es setzt den Text in dem Stil fort, der zu seiner Schulungsstruktur passt. Ein vorab trainiertes Modell vervollständigt die Anweisungen automatisch, statt sie zu befolgen, erzeugt eine inkonsistente Formatierung und kann unerwünschte Verzerrungen oder unsichere Inhalte aus den Trainingsdaten wiedergeben. Pre-training fördert die allgemeine Kompetenz, nicht den Nutzen einer Aufgabe.

Post-training verwandelt den Mustervervollständiger in einen nützlichen Assistenten. Sie führen mehrere Runden von Supervised Fine-Tuning (SFT) durch, um dem Modell beizubringen, Anweisungen zu befolgen, Schemata und Richtlinien einzuhalten, Tools aufzurufen und zuverlässige Ergebnisse zu erzielen, indem Sie hochwertige Demonstrationen imitieren. Durch diese Ausrichtung lernt das Modell, auf Eingabeaufforderungen als Aufgaben und nicht als Text zu reagieren, um fortzufahren. Anschließend wenden Sie Reinforcement Fine-Tuning (RFT) an, um das Verhalten mithilfe von messbarem Feedback (z. B. Prüfer oder einem LLM-as-a-judge) zu optimieren, wobei Kompromisse wie Genauigkeit und Kürze, Sicherheit und Umfang oder mehrstufiges Denken unter Berücksichtigung von Einschränkungen abgewogen werden. In der Praxis wechseln Sie SFT und RFT zyklisch ab, um aus dem vorab trainierten Modell ein zuverlässiges, richtliniengerechtes System zu machen, das komplexe Aufgaben konsistent ausführt.

## Wählen Sie den richtigen Anpassungsansatz

In diesem Abschnitt werden wir uns mit Strategien zur Anpassung nach dem Training befassen: RFT und SFT.

### Feinabstimmung der Verstärkung (RFT)

Die Feinabstimmung der Verstärkung verbessert die Modellleistung durch Feedbacksignale — messbare Werte oder Belohnungen, die auf die Qualität der Antworten hinweisen — und nicht durch direkte Überwachung mit exakt richtigen Antworten. Im Gegensatz zur herkömmlichen überwachten Feinabstimmung, die aus Input-Output-Paaren lernt, verwendet RFT Belohnungsfunktionen, um die Modellantworten zu bewerten, und optimiert das Modell iterativ, um diese Belohnungen zu maximieren. Dieser Ansatz eignet sich gut für Aufgaben, bei denen es schwierig ist, den exakt richtigen Output zu definieren, aber Sie können die Qualität der Antworten zuverlässig messen. RFT ermöglicht es Modellen, komplexe Verhaltensweisen und Präferenzen durch Ausprobieren und Feedback zu erlernen, und eignet sich daher ideal für Anwendungen, die eine nuancierte Entscheidungsfindung, kreative Problemlösung oder die Einhaltung bestimmter Qualitätskriterien erfordern, die Sie programmgesteuert bewerten können. Die Beantwortung komplexer Rechtsfragen ist beispielsweise ein idealer Anwendungsfall für RFT, da Sie dem Modell beibringen möchten, besser zu argumentieren, um Fragen genauer zu beantworten.

### Funktionsweise

Bei der Feinabstimmung von Verstärkungen gehen Sie von einer auf Anweisungen abgestimmten Ausgangsbasis aus und behandeln jede Aufforderung wie ein kleines Turnier. Für eine bestimmte Eingabe nehmen Sie eine Stichprobe von einer Handvoll Kandidatenantworten aus dem Modell,

bewerten jede einzelne mit der Belohnungsfunktion und ordnen sie dann innerhalb dieser Gruppe ein. Durch den Aktualisierungsschritt wird das Modell so angepasst, dass beim nächsten Mal die Wahrscheinlichkeit von Kandidaten mit einer höheren Punktzahl steigt und die Wahrscheinlichkeit von Kandidaten mit niedrigerer Punktzahl verringert wird, während eine Beschränkung, die nahe am Ausgangswert bleibt, verhindert, dass das Verhalten abdriftet, ausführlich oder ausbeuterisch wird. Sie wiederholen diese Schleife bei vielen Eingabeaufforderungen, aktualisieren schwierige Fälle, verschärfen die Prüfer- oder Richterrubriken, wenn Sie Exploits sehen, und verfolgen kontinuierlich Aufgabenmetriken.

### Wann sollte RFT verwendet werden

Aufgaben, die am meisten von RFT profitieren, haben mehrere Merkmale gemeinsam. Sie haben messbare Erfolgssignale, auch wenn es schwierig ist, eine einzelne korrekte Ausgabe zu spezifizieren. Sie geben teilweise Anerkennung oder benotete Qualität, sodass Sie innerhalb einer Aufforderung oder mithilfe einer Belohnungsfunktion bessere oder schlechtere Antworten bewerten können. Sie beinhalten mehrere Ziele, die gegeneinander abgewogen werden müssen (z. B. Genauigkeit und Kürze, Klarheit, Sicherheit oder Kosten). Sie erfordern die Einhaltung ausdrücklicher Einschränkungen, die Sie programmgesteuert überprüfen können. Sie funktionieren in toolgestützten oder umgebungsbasierten Umgebungen, in denen Ergebnisse beobachtbar sind (Erfolg oder Misserfolg, Latenz, Ressourcennutzung). Sie treten in Ländern auf, in denen das Sammeln von Goldzielen teuer ist, aber automatisiertes oder rubrikbasiertes Feedback in Hülle und Fülle vorhanden ist. RFT funktioniert am besten, wenn Sie Qualität in einen zuverlässigen Skalar oder ein zuverlässiges Ranking umwandeln können und möchten, dass das Modell Verhaltensweisen mit höheren Punktzahlen bevorzugt verstärkt, ohne dass erschöpfende, beschriftete Ziele erforderlich sind.

Ziehen Sie andere Methoden in Betracht, wenn:

- Sie haben zahlreiche, zuverlässig beschriftete Eingangs-/Ausgangspaare — verwenden Sie SFT
- Die größte Lücke ist Wissen oder Fachjargon — nutzen Sie Retrieval-Augmented Generation (RAG)
- Dein Belohnungssignal ist verrauscht oder unzuverlässig und du kannst es nicht mit besseren Rubriken oder Checkern beheben. Stabilisiere das zuerst, bevor du RFT

Wann sollte RFT nicht verwendet werden

Vermeiden Sie RFT in diesen Situationen:

- Sie können kostengünstig zuverlässige, beschriftete Eingangs-/Ausgangspaare herstellen (SFT ist einfacher, billiger und stabiler)
- Die Lücke ist eher Wissen oder Fachjargon als Verhalten (verwenden Sie RAG)
- Ihr Belohnungssignal ist laut, spärlich, einfach zu spielen oder teuer oder langsam zu berechnen (korrigieren Sie zuerst den Evaluator)
- Die Ausgangsleistung liegt nahe Null (zuerst mit SFT starten, bevor die Einstellungen optimiert werden)
- Die Aufgabe hat deterministische Schemata, eine strenge Formatierung oder eine einzige richtige Antwort (SFT oder regelbasierte Validierung funktioniert besser)
- Enge Latenz- oder Kostenbudgets können die zusätzlichen Probenahme- oder Explorationskosten, die RFT erfordert, nicht auffangen
- Sicherheits- oder politische Einschränkungen sind in der Prämie nicht klar spezifiziert und durchsetzbar

Wenn Sie auf „die richtige Antwort“ hinweisen können, verwenden Sie SFT. Wenn Sie neues Wissen benötigen, verwenden Sie RAG. Verwenden Sie RFT erst, wenn Sie über eine solide Ausgangsbasis und eine robuste, schnelle und schwer zu nutzende Belohnungsfunktion verfügen.

## Überwachte Optimierung (SFT)

Die überwachte Feinabstimmung trainiert das LLM anhand eines Datensatzes von von Menschen beschrifteter Input-Output-Paare für Ihre Aufgabe. Sie geben Beispiele für Eingabeaufforderungen (Fragen, Anweisungen usw.) mit den richtigen oder gewünschten Antworten und setzen das Training des Modells anhand dieser Beispiele fort. Das Modell passt seine Gewichtungen an, um einen überwachten Verlust zu minimieren (in der Regel eine Kreuzentropie zwischen seinen Vorhersagen und den Ziel-Output-Token). Dabei handelt es sich um dasselbe Training, das bei den meisten Aufgaben des überwachten maschinellen Lernens zur Spezialisierung eines LLM verwendet wird.

SFT verändert Verhalten, nicht Wissen. Es bringt dem Modell keine neuen Fakten oder Fachjargon bei, die es vor dem Training nicht gesehen hat. Es bringt dem Modell bei, wie man antwortet, nicht, was es wissen soll. Wenn Sie neues Fachwissen benötigen (z. B. interne Terminologie), verwenden Sie Retrieval-Augmented Generation (RAG), um diesen Kontext zum Zeitpunkt der Inferenz bereitzustellen. SFT fügt dann das gewünschte Verhalten bei der Befolgung von Anweisungen hinzu.



## Funktionsweise

SFT optimiert LLM, indem es den durchschnittlichen Kreuzentropieverlust bei Antwort-Token minimiert, Prompt-Token als Kontext behandelt und sie vor dem Verlust maskiert. Das Modell verinnerlicht Ihren Zielstil, Ihre Struktur und Ihre Entscheidungsregeln und lernt, für jede Aufforderung die richtige Antwort zu generieren. Um Dokumente beispielsweise in benutzerdefinierte Kategorien zu klassifizieren, optimieren Sie das Modell mithilfe von Eingabeaufforderungen (dem Dokumenttext) und beschrifteten Vervollständigungen (den Kategoriebeschriftungen). Sie trainieren mit diesen Paaren, bis das Modell für jede Aufforderung mit hoher Wahrscheinlichkeit die richtige Bezeichnung ausgibt.

Sie können SFT mit nur ein paar hundert Beispielen durchführen und bis zu einigen hunderttausend skalieren. SFT-Proben müssen von hoher Qualität sein und direkt auf das gewünschte Modellverhalten abgestimmt sein.

### Wann sollte SFT verwendet werden

Verwenden Sie SFT, wenn Sie eine klar definierte Aufgabe mit eindeutig gewünschten Ergebnissen haben. Wenn Sie explizit angeben können, dass „Bei gegebener X-Eingabe ist die richtige Ausgabe Y“ und Beispiele für solche Zuordnungen sammeln können, ist die überwachte Feinabstimmung eine gute Wahl. SFT zeichnet sich in diesen Szenarien aus:

- Strukturierte oder komplexe Klassifizierungsaufgaben — Klassifizieren Sie interne Dokumente oder Verträge in viele benutzerdefinierte Kategorien. Mit SFT lernt das Modell diese spezifischen Kategorien besser kennen, als wenn es nur Eingabeaufforderungen erfordert.
- Question-answering oder Transformationsaufgaben mit bekannten Antworten — Fine-tune ein Modell zur Beantwortung von Fragen aus der Wissensdatenbank eines Unternehmens oder zur Konvertierung von Daten zwischen Formaten, bei denen jede Eingabe eine korrekte Antwort hat.
- Einheitlichkeit bei Formatierung und Stil — Trainieren Sie das Modell so, dass es immer in einem bestimmten Format oder Ton reagiert, indem Sie anhand von Beispielen für das richtige Format oder den richtigen Ton Feinabstimmungen vornehmen. Wenn das Modell beispielsweise anhand von Paaren zwischen Aufforderung und Antwort trainiert wird, die eine bestimmte Markensprache zum Ausdruck bringen, wird dem Modell beigebracht, Outputs mit diesem Stil zu generieren. Instruction-following Verhalten wird häufig zunächst durch SFT anhand von kuratierten Beispielen für gutes Assistenzverhalten vermittelt.

SFT ist der direkteste Weg, einem LLM eine neue Fähigkeit oder ein neues Verhalten beizubringen, wenn Sie angeben können, wie das richtige Verhalten aussieht. Es nutzt das vorhandene

Sprachverständnis des Modells und konzentriert es auf Ihre Aufgabe. Verwenden Sie SFT, wenn Sie möchten, dass das Modell eine bestimmte Aufgabe erfüllt und Sie einen Datensatz mit Beispielen haben oder erstellen können.

Verwenden Sie SFT, wenn Sie qualitativ hochwertige Eingabeaufforderungs- und Antwortpaare zusammenstellen können, die das gewünschte Verhalten genau widerspiegeln. Es eignet sich für Aufgaben mit klaren Zielen oder deterministischen Formaten wie Schemas, Funktions- oder Toolaufrufen sowie für strukturierte Antworten, bei denen Nachahmung ein geeignetes Trainingssignal ist. Das Ziel ist die Verhaltensformung: Dem Modell beizubringen, Eingabeaufforderungen als Aufgaben zu behandeln, Anweisungen zu befolgen, Ton- und Ablehnungsrichtlinien anzunehmen und eine einheitliche Formatierung zu gewährleisten. Planen Sie mindestens Hunderte von Demonstrationen ein, bei denen Datenqualität, Konsistenz und Deduplizierung wichtiger sind als das reine Volumen. Für ein unkompliziertes, kosteneffizientes Update sollten Sie parametereffiziente Methoden wie Low-Rank Adaptation verwenden, um kleine Adapter zu trainieren und dabei den Großteil des Backbones unangetastet zu lassen.

Wann sollte SFT nicht verwendet werden

Verwenden Sie SFT nicht, wenn die Lücke eher im Wissen als im Verhalten besteht. Es vermittelt dem Modell keine neuen Fakten, Fachjargon oder aktuelle Ereignisse. Verwenden Sie in diesen Fällen die Generierung mit erweitertem Abruf, um externes Wissen als Inferenz heranzuziehen. Vermeiden Sie SFT, wenn Sie die Qualität messen können, aber keine einzige richtige Antwort angeben können. Verwenden Sie die Feinabstimmung der Verstärkung mit überprüfbaren Belohnungen oder einer, um diese Prämien LLM-as-a-judge direkt zu optimieren. Wenn sich Ihre Bedürfnisse oder Inhalte häufig ändern, verlassen Sie sich auf den Abruf und die Verwendung von Tools, anstatt das Modell erneut zu trainieren.

Themen

- [Nova Forge SDK](#)
- [Schulung für Amazon Nova-Modelle](#)
- [Überwachung des Fortschritts über mehrere Iterationen hinweg](#)
- [Evaluieren Sie Ihr SageMaker AI-trained Modell](#)
- [Iteratives Training](#)

# Nova Forge SDK

Das Nova Forge SDK ist ein umfassendes Python-SDK zur Anpassung von Amazon Nova-Modellen. Das SDK bietet eine einheitliche Oberfläche für Training, Evaluierung, Überwachung, Bereitstellung und Inferenz von Amazon Nova-Modellen auf verschiedenen Plattformen, einschließlich SageMaker KI und Amazon Bedrock. Ganz gleich, ob Sie Modelle an domänenspezifische Aufgaben anpassen oder die Leistung für Ihren Anwendungsfall optimieren möchten, dieses SDK bietet alles, was Sie benötigen, in einer einheitlichen Oberfläche.

## Quick Links

Gehen Sie wie folgt vor, um von der Installation zu Ihrem ersten Schulungsjob zu gelangen:

- [SDK-Referenz](#) — Dokumentation und Verwendungsspezifikation
- [Quick Start Notebook](#) — Interaktives Python-Notizbuch für praktische Erkundungen

## Vorteile

- Ein SDK für den gesamten Lebenszyklus der Modellanpassung — von der Datenvorbereitung über die Bereitstellung bis hin zur Überwachung.
- Support mehrerer Trainingsmethoden, darunter Continued Pre-Training (CPT), Supervised Fine-Tuning (SFT), Direct Preference Optimization (DPO) und Reinforcement Fine-Tuning (RFT), sowohl mit Singleturn als auch mit Multi-Turn, sowohl mit LoRa- als auch mit Full-Rank-Ansätzen.
- Built-in Unterstützung für SageMaker Training Jobs und Amazon Bedrock mit automatischem Ressourcenmanagement. SageMaker HyperPod
- Sie müssen nicht mehr nach den richtigen Rezepten oder Container-URI für Ihre Trainingstechniken suchen.
- Bringen Sie Ihre eigenen Trainingsrezepte mit oder verwenden Sie die intelligenten Standardeinstellungen des SDK mit Parameterüberschreibungen.
- Das SDK validiert Ihre Konfiguration anhand unterstützter Modell- und Instanzkombinationen und bietet Validierungsunterstützung, wodurch Fehler vor Trainingsbeginn vermieden werden.
- Mit der integrierten CloudWatch Amazon-Überwachung können Sie den Trainingsfortschritt in Echtzeit verfolgen.
- Integrierter MLflow zur Verfolgung von Trainingsexperimenten mit SageMaker KI-MLflow-Tracking-Servern.

## Voraussetzungen

### Unterstützte Python-Versionen

Das Nova Forge SDK wurde getestet auf:

- Python 3.12

### Installation

Um dieses SDK zu installieren, folgen Sie bitte dem folgenden Befehl.

```
pip install amzn-nova-forge
```

### Unterstützte Modelle und Techniken

Das SDK unterstützt die folgenden Modelle und Techniken innerhalb der Amazon Nova-Familie:

| Methode                                      | Unterstützte Modelle                                  |
|----------------------------------------------|-------------------------------------------------------|
| Fortsetzung Pre-training                     | <a href="#">Alle Nova-Modelle</a> (nur SMHP)          |
| Betreute LoRa Fine-tuning                    | <a href="#">Alle Nova-Modelle</a>                     |
| Beaufsichtigt Fine-tuning Full-Rank          | <a href="#">Alle Nova-Modelle</a> (nur SMHP und SMTJ) |
| Direkte Präferenzoptimierung LoRa            | Nova 1.0-Modelle (nur SMHP und SMTJ)                  |
| Direkte Präferenzoptimierung Full-Rank       | Nova 1.0-Modelle (nur SMHP und SMTJ)                  |
| Fine-tuning Verstärkung LoRa                 | Nova Lite 2.0                                         |
| Verstärkung Fine-tuning Full-Rank            | Nova Lite 2.0 (nur SMHP und SMTJ)                     |
| Multi-turn Fine-tuning Verstärkung LoRa      | Nova Lite 2.0 (nur SMHP)                              |
| Multi-turn Verstärkung Fine-tuning Full-Rank | Nova Lite 2.0 (nur SMHP)                              |

# Erste Schritte

## Themen

- [1. Bereiten Sie Ihre Daten vor](#)
- [2. Konfigurieren Sie Ihre Infrastruktur](#)
- [3. Trainieren](#)
- [4. Überwachen](#)
- [5. Evaluieren](#)
- [6. Bereitstellen](#)

### 1. Bereiten Sie Ihre Daten vor

Laden Sie Ihren Datensatz aus lokalen Dateien oder S3 und lassen Sie das SDK die Transformation in das richtige Format für die von Ihnen gewählte Trainingsmethode durchführen. Oder stellen Sie formatierte Daten bereit und legen Sie sofort los.

```
from amzn_nova_forge.dataset.dataset_loader import JSONLDatasetLoader
from amzn_nova_forge.model.model_enums import Model, TrainingMethod, TransformMethod

loader = JSONLDatasetLoader()
loader.load("s3://your-bucket/training-data.jsonl")
loader.transform(
 method=TransformMethod.SCHEMA,
 training_method=TrainingMethod.SFT_LORA,
 model=Model.NOVA_LITE_2,
 column_mappings={"question": "input", "answer": "output"},
)
```

### 2. Konfigurieren Sie Ihre Infrastruktur

Wählen Sie Ihre Rechenressourcen aus — das SDK validiert Konfigurationen und sorgt für eine optimale Einrichtung.

```
from amzn_nova_forge.manager.runtime_manager import BedrockRuntimeManager,
SMTJRuntimeManager, SMTJServerlessRuntimeManager, SMHPRuntimeManager

Bedrock
runtime = BedrockRuntimeManager(
```

```

execution_role="arn:aws:iam::123456789012:role/ExampleRole"
)

SageMaker Training Jobs
runtime = SMTJRuntimeManager(
 instance_type="ml.p5.48xlarge",
 instance_count=4
)

SageMaker Training Jobs Serverless
runtime = SMTJServerlessRuntimeManager(
 model_package_group_name = "my-package"
)

SageMaker HyperPod
runtime = SMHPRuntimeManager(
 instance_type="ml.p5.48xlarge",
 instance_count=4,
 cluster_name="my-hyperpod-cluster",
 namespace="kubeflow"
)

```

### 3. Trainieren

Beginnen Sie das Training mit nur wenigen Codezeilen.

```

from amzn_nova_forge.trainer.forge_trainer import ForgeTrainer
from amzn_nova_forge.model.model_enums import Model, TrainingMethod
from amzn_nova_forge.core import ForgeConfig

trainer = ForgeTrainer(
 model=Model.NOVA_LITE_2,
 method=TrainingMethod.SFT_LORA,
 infra=runtime,
 training_data_s3_path="s3://your-bucket/sft/prepared-data.jsonl", # Training data
 path
 config=ForgeConfig(
 output_s3_path="s3://your-bucket/output",
),
)

result = trainer.train(job_name="my-training-job")

```

## 4. Überwachen

Verfolgen Sie Ihren Trainingsfortschritt direkt im SDK.

```
from amzn_nova_forge.monitor.log_monitor import CloudWatchLogMonitor

Monitor training logs
trainer.get_logs()

Or monitor directly via CloudWatchLogMonitor
monitor = CloudWatchLogMonitor.from_job_result(result)
monitor.show_logs(limit=10)

Check job status
result.get_job_status() # InProgress, Completed, Failed
```

## 5. Evaluieren

Bewerten Sie die Modellleistung mit einer Vielzahl [integrierter Benchmarks](#) oder entwerfen Sie Ihre eigenen Bewertungen.

```
from amzn_nova_forge.evaluator import ForgeEvaluator
from amzn_nova_forge.recipe_config.eval_config import EvaluationTask

evaluator = ForgeEvaluator(
 model=Model.NOVA_LITE_2,
 infra=runtime,
 config=ForgeConfig(
 output_s3_path="s3://your-bucket/output",
),
 data_s3_path="s3://your-bucket/eval-data/data.jsonl"
)

Evaluate on benchmark tasks
eval_result = evaluator.evaluate(
 job_name="model-eval",
 eval_task=EvaluationTask.MMLU,
 model_path=result.model_artifacts.checkpoint_s3_path
)
```

## 6. Bereitstellen

Implementieren Sie Ihr maßgeschneidertes Modell in der Produktion mit integrierter Unterstützung für Amazon Bedrock oder SageMaker.

```
from amzn_nova_forge.deployer import ForgeDeployer
from amzn_nova_forge.model.model_enums import DeployPlatform

deployer = ForgeDeployer(
 region="us-east-1",
 model=Model.NOVA_LITE_2,
)

Bedrock provisioned throughput
deployment = deployer.deploy(
 model_artifact_path=result.model_artifacts.checkpoint_s3_path,
 deploy_platform=DeployPlatform.BEDROCK_PT,
 unit_count=10
)

Bedrock On-Demand
deployment = deployer.deploy(
 model_artifact_path=result.model_artifacts.checkpoint_s3_path,
 deploy_platform=DeployPlatform.BEDROCK_OD
)

Sagemaker Real-time Inference
deployment = deployer.deploy(
 model_artifact_path=result.model_artifacts.checkpoint_s3_path,
 deploy_platform=DeployPlatform.SAGEMAKER,
 unit_count=10,
 sagemaker_instance_type="ml.p5.48xlarge",
 sagemaker_environment_variables={
 "CONTEXT_LENGTH": "12000",
 "MAX_CONCURRENCY": "16",
 }
)
```



## Die wichtigsten Funktionen

### Rezepterstellung im Handumdrehen

Das SDK macht die Suche nach den entsprechenden Rezepten oder Container-URI für bestimmte Techniken überflüssig.

### Intelligente Datenverarbeitung

Das SDK wandelt Ihre Daten automatisch in das richtige Format für das Training um. Egal, ob Sie mit JSON-, JSONL- oder CSV-Dateien arbeiten, der Data Loader wickelt die Konvertierung nahtlos ab. Data Loader unterstützt sowohl Text als auch multimodale Daten (Bilder und Videos).

### Support der Unternehmensinfrastruktur

Das SDK funktioniert sowohl mit SageMaker Training Jobs als auch SageMaker HyperPod mit der automatischen Verwaltung von:

- Validierung des Instanztyps
- Validierung des Rezepts
- Datensatzvalidierung
- Orchestrierung und Überwachung von Job

Das SDK unterstützt auch serverlose SageMaker Trainingsjobs und die Anpassung von Bedrock.

### Umfassende Bewertung

Bewerten Sie Ihre maßgeschneiderten Modelle anhand von [Standard-Benchmarks](#), darunter:

- MMLU (Massives Multitasking Language Understanding)
- BBH (Aufgaben zum Denken für Fortgeschrittene)
- GPQA (Fragen und Antworten) Graduate-Level Google-Proof

Verwenden Sie entweder die Benchmark-StandardEinstellungen oder passen Sie sie an Ihre Bedürfnisse an:

- BYOM (Bringen Sie Ihre eigene Metrik mit)
- BYOD (Bringen Sie Ihren eigenen Datensatz mit)

## Einsatz in der Produktion

Stellen Sie Ihre Modelle auf Amazon Bedrock oder SageMaker AI bereit und bieten Sie Optionen für:

- Bedrock Provisioned Throughput — Dedizierte Kapazität für gleichbleibende Leistung
- Bedrock On-Demand (gilt nur für LoRa-basierte Anpassungen) — Preisgestaltung Pay-per-use
- SageMaker KI Real-time Inference — Dedizierte Kapazität für gleichbleibende Leistung

## Batch-Inferenz

Führen Sie umfangreiche Inferenzjobs effizient aus:

- Verarbeiten Sie Tausende von Anfragen parallel
- Automatische Ergebnisaggregation
- Cost-effective Batch-Verarbeitung

## Nova Forge

Für Abonnenten von Nova Forge unterstützt das SDK Rezepte zum Mischen von Daten.

## Weitere Informationen

Sind Sie bereit, mit der Anpassung von Nova-Modellen mit dem Nova Forge SDK zu beginnen? In unserem GitHub Repository finden Sie ausführliche Anleitungen, API-Referenzen und weitere Beispiele: <https://github.com/aws/nova-forge-sdk>

## Schulung für Amazon Nova-Modelle

Das Training von Amazon Nova-Modellen auf SageMaker Training Jobs unterstützt Supervised Fine-Tuning (SFT) und Reinforcement Fine-Tuning (RFT). Jede Technik erfüllt unterschiedliche Anpassungsanforderungen und kann auf verschiedene Amazon Nova-Modellversionen angewendet werden.

## Themen

- [Nova 2.0 fein abstimmen](#)
- [Verstärkung Fine-Tuning \(RFT\) mit Amazon Nova-Modellen](#)

## Nova 2.0 fein abstimmen

### Voraussetzungen

Bevor Sie einen Trainingsjob beginnen, sollten Sie Folgendes beachten.

- Amazon-S3-Buckets zum Speichern Ihrer Eingabedaten und der Ausgabe von Trainingsjobs. Sie können entweder einen Bucket für beide oder separate Buckets für jeden Datentyp verwenden. Stellen Sie sicher, dass sich Ihre Bereiche dort befinden AWS-Region , wo Sie auch alle anderen Ressourcen für Schulungen erstellen. Weitere Informationen finden Sie unter [Erstellen eines Buckets für allgemeine Zwecke](#).
- Eine IAM-Rolle mit Berechtigungen zum Ausführen eines Trainingsjobs. Stellen Sie sicher, dass Sie eine IAM-Richtlinie mit `AmazonSageMakerFullAccess` anhängen. Weitere Informationen finden Sie unter [So verwenden Sie SageMaker KI-Ausführungsrollen](#).
- Grundlegende Amazon-Nova-Rezepte finden Sie unter [???](#).

### Was ist SFT?

Supervised Fine-Tuning (SFT) trainiert ein Sprachmodell mithilfe von beschrifteten Eingabe-Ausgabe-Paaren. Das Modell lernt anhand von Demonstrationsbeispielen, die aus Eingabeaufforderungen und Antworten bestehen, und verfeinert seine Fähigkeiten, um es an bestimmte Aufgaben, Anweisungen oder erwünschte Verhaltensweisen anzupassen.

### Datenaufbereitung

#### -Übersicht

Nova 2.0-SFT-Daten verwenden dasselbe Converse-API-Format wie Nova 1.0, mit zusätzlichen optionalen Inhaltsfeldern für Argumentation. Vollständige Formatspezifikationen finden Sie unter:

- Inhalt der Argumentation: [ReasoningContentBlock](#)
- [Converse API-Schema: Converse API](#)
- [Datensatz-Einschränkungen: Datensatz-Einschränkungen](#)

### Unterstützte Features

- Eingabearten — Text, Bild oder Video in Inhaltsblöcken für Benutzer
- Assistenteninhalte — Reine Textantworten und Argumentationsinhalte

- Zusammensetzung des Datensatzes — Muss homogen sein. Wählen Sie eine der folgenden Optionen:
  - Reine Text-Wendungen
  - Text- und Bilddrehungen
  - Text und Videodrehungen (unterstützt das Verständnis von Dokumenten)

 **Important**

Sie können Bilder und Videos nicht innerhalb desselben Datensatzes oder in verschiedenen Zügen mischen.

### Aktuelle Einschränkungen

- Inhalte zum multimodalen Denken — Obwohl das Converse-Format bildbasierte Argumentationsinhalte unterstützt, unterstützt Nova 2.0 SFT nur textbasierte Argumentationsinhalte im Feld ReasoningText.
- Validierungssätze — Sie können mit Nova 2.0 keinen Validierungsdatensatz für SFT bereitstellen. Wenn Sie einen Validierungsdatensatz angeben, wird dieser während des Trainings ignoriert. Diese Einschränkung gilt sowohl für UI-basierte als auch für programmatische Jobeinreichungen.

### Unterstützte Medienformate

- Bilder — PNG, JPEG, GIF
- Videos — MOV, MKV, MP4

### Beispiele für Datenformate

#### Text-only (Nova 1.0 compatible)

```
{
 "schemaVersion": "bedrock-conversation-2024",
 "system": [
 {
 "text": "You are a digital assistant with a friendly personality"
 }
],
}
```

```
"messages": [
 {
 "role": "user",
 "content": [
 {
 "text": "What country is right next to Australia?"
 }
]
 },
 {
 "role": "assistant",
 "content": [
 {
 "text": "The closest country is New Zealand"
 }
]
 }
]
```

### Text with reasoning (Nova 2.0)

```
{
 "schemaVersion": "bedrock-conversation-2024",
 "system": [
 {
 "text": "You are a digital assistant with a friendly personality"
 }
],
 "messages": [
 {
 "role": "user",
 "content": [
 {
 "text": "What country is right next to Australia?"
 }
]
 },
 {
 "role": "assistant",
 "content": [
 {
 "reasoningContent": {
```

```

 "reasoningText": {
 "text": "I need to use my world knowledge of geography to answer this
question"
 }
 },
 {
 "text": "The closest country to Australia is New Zealand, located to the
southeast across the Tasman Sea."
 }
]
}

```

## Image + text input

```

{
 "schemaVersion": "bedrock-conversation-2024",
 "system": [
 {
 "text": "You are a helpful assistant."
 }
],
 "messages": [
 {
 "role": "user",
 "content": [
 {
 "image": {
 "format": "jpeg",
 "source": {
 "s3Location": {
 "uri": "s3://your-bucket/your-path/your-image.jpg",
 "bucketOwner": "your-aws-account-id"
 }
 }
 }
 },
 {
 "text": "Which country is highlighted in the image?"
 }
]
 }
]
}

```

```
 },
 {
 "role": "assistant",
 "content": [
 {
 "reasoningContent": {
 "reasoningText": {
 "text": "I will determine the highlighted country by examining its
location on the map and using my geographical knowledge"
 }
 }
 },
 {
 "text": "The highlighted country is New Zealand"
 }
]
 }
]
}
```

## Video + text input

```
{
 "schemaVersion": "bedrock-conversation-2024",
 "system": [
 {
 "text": "You are a helpful assistant."
 }
],
 "messages": [
 {
 "role": "user",
 "content": [
 {
 "video": {
 "format": "mp4",
 "source": {
 "s3Location": {
 "uri": "s3://your-bucket/your-path/your-video.mp4",
 "bucketOwner": "your-aws-account-id"
 }
 }
 }
 }
]
 }
]
}
```

```
 },
 {
 "text": "What is shown in this video?"
 }
],
},
{
 "role": "assistant",
 "content": [
 {
 "reasoningContent": {
 "reasoningText": {
 "text": "I will analyze the video content to identify key elements"
 }
 }
 },
 {
 "text": "The video shows a map with New Zealand highlighted"
 }
]
}
]
```

## Aufrufen von Tools

Nova 2.0 SFT unterstützt Trainingsmodelle anhand von Werkzeugaufrufmustern, sodass Ihr Modell lernen kann, wann und wie externe Tools oder Funktionen aufgerufen werden müssen.

### Datenformat für den Werkzeugaufruf

Zu den Trainingsdaten für das Aufrufen von Tools gehört ein `toolConfig` Abschnitt, in dem die verfügbaren Tools definiert sind, sowie Konversationsrunden, in denen die Verwendungsmuster der Tools veranschaulicht werden.

### Beispieleingabe

```
{
 "schemaVersion": "bedrock-conversation-2024",
 "system": [
 {
 "text": "You are an expert in composing function calls."
 }
]
}
```



```

 }
],
 "toolConfig": {
 "tools": [
 {
 "toolSpec": {
 "name": "getItemCost",
 "description": "Retrieve the cost of an item from the catalog",
 "inputSchema": {
 "json": {
 "type": "object",
 "properties": {
 "item_name": {
 "type": "string",
 "description": "The name of the item to retrieve cost for"
 },
 "item_id": {
 "type": "string",
 "description": "The ASIN of item to retrieve cost for"
 }
 }
 },
 "required": [
 "item_id"
]
 }
 }
 }
],
 {
 "toolSpec": {
 "name": "getItemAvailability",
 "description": "Retrieve whether an item is available in a given location",
 "inputSchema": {
 "json": {
 "type": "object",
 "properties": {
 "zipcode": {
 "type": "string",
 "description": "The zipcode of the location to check in"
 },
 "quantity": {
 "type": "integer",
 "description": "The number of items to check availability for"
 }
 }
 }
 }
 }
]
 }
}

```

```

 "item_id": {
 "type": "string",
 "description": "The ASIN of item to check availability for"
 },
 "required": [
 "item_id", "zipcode"
]
 }
}

},
"messages": [
 {
 "role": "user",
 "content": [
 {
 "text": "I need to check whether there are twenty pieces of the following item available. Here is the item ASIN on Amazon: id-123. Please check for the zipcode 94086"
 }
]
 },
 {
 "role": "assistant",
 "content": [
 {
 "reasoningContent": {
 "reasoningText": {
 "text": "The user wants to check how many pieces of the item with ASIN id-123 are available in the zipcode 94086"
 }
 }
 }
]
 },
 {
 "toolUse": {
 "toolUseId": "getItemAvailability_0",
 "name": "getItemAvailability",
 "input": {
 "zipcode": "94086",
 "quantity": 20,
 "item_id": "id-123"
 }
 }
 }
]
}

```

```

 }
 }
}
],
{
 "role": "user",
 "content": [
 {
 "toolResult": {
 "toolUseId": "getItemAvailability_0",
 "content": [
 {
 "text": "[{\"name\": \"getItemAvailability\", \"results\": {\"availability\": true}}]"
 }
]
 }
 }
]
},
{
 "role": "assistant",
 "content": [
 {
 "text": "Yes, there are twenty pieces of item id-123 available at 94086. Would you like to place an order or know the total cost?"
 }
]
}
]
}
}

```

## Anforderungen für das Aufrufen von Tools

Beachten Sie bei der Erstellung von Trainingsdaten für Tool-Calls die folgenden Anforderungen:

| Anforderung         | Description                                              |
|---------------------|----------------------------------------------------------|
| ToolUse Platzierung | ToolUse darf nur in der Runde des Assistenten erscheinen |

| Anforderung               | Description                                                                                                                                                                               |
|---------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| ToolResult Platzierung    | ToolResult darf nur abwechselnd vom Benutzer angezeigt werden                                                                                                                             |
| ToolResult Format         | ToolResult sollte nur Text oder JSON sein. Andere Modalitäten werden für Nova-Modelle nicht unterstützt                                                                                   |
| InputSchema-Format        | Das InputSchema in der ToolSpec muss ein gültiges JSON-Schemaobjekt sein                                                                                                                  |
| toolUseId übereinstimmend | Jeder ToolResult muss auf ein gültiges Element toolUseId eines vorhergehenden Assistenten verweisen ToolUse, wobei jeder Assistent genau einmal pro Konversation toolUseId verwendet wird |

## Wichtige Hinweise

- Stellen Sie sicher, dass Ihre Tooldefinitionen in allen Trainingsbeispielen konsistent sind
- Das Modell lernt anhand der von Ihnen bereitgestellten Demonstrationen Muster für den Aufruf von Tools
- Geben Sie verschiedene Beispiele an, wann die einzelnen Tools verwendet werden sollten und wann nicht

## Verstehen von Dokumenten

Nova 2.0 SFT unterstützt Schulungen zu dokumentenbasierten Aufgaben, sodass Ihr Modell lernen kann, wie man PDF-Dokumente analysiert und Fragen zu ihnen beantwortet.

### Datenformat für das Verständnis von Dokumenten

Zu den Trainingsdaten für das Dokumentenverständnis gehören Dokumentverweise in den Inhaltsblöcken für den Benutzer, wobei das Modell lernt, den Inhalt des Dokuments zu extrahieren und zu analysieren.

### Eingabebeispiel

```
{
 {
 "schemaVersion": "bedrock-conversation-2024",
```

```
"messages": [
 {
 "role": "user",
 "content": [
 {
 "text": "What are the ways in which a customer can experience issues during checkout on Amazon?"
 },
 {
 "document": {
 "format": "pdf",
 "source": {
 "s3Location": {
 "uri": "s3://my-bucket-name/path/to/documents/customer_service_debugging.pdf",
 "bucketOwner": "123456789012"
 }
 }
 }
 }
]
 },
 {
 "role": "assistant",
 "content": [
 {
 "reasoningContent": {
 "reasoningText": {
 "text": "I need to find the relevant section in the document to answer the question."
 }
 }
 },
 {
 "text": "Customers can experience issues with 1. Data entry, 2. Payment methods, 3. Connectivity while placing the order. Which one would you like to dive into?"
 }
]
 }
]
```

## Einschränkungen beim Verständnis von Dokumenten

| Einschränkung           | Details                                                                                                                                  |
|-------------------------|------------------------------------------------------------------------------------------------------------------------------------------|
| Unterstütztes Format    | Nur PDF-Dateien                                                                                                                          |
| Maximale Dokumentgröße  | 10 MB                                                                                                                                    |
| Mischen von Modalitäten | Ein Beispiel kann Dokumente und Text enthalten, aber es ist nicht möglich, Dokumente mit anderen Modalitäten (Bilder, Videos) zu mischen |

## Bewährte Methoden für das Verständnis von Dokumenten

- Stellen Sie sicher, dass Dokumente klar formatiert sind und der Text extrahierbar ist
- Geben Sie verschiedene Beispiele für verschiedene Dokumenttypen und Fragenformate an
- Fügen Sie Argumentationsinhalte hinzu, um dem Modell zu helfen, Muster für die Dokumentenanalyse zu erlernen

## Video-Verständnis

Nova 2.0 SFT unterstützt Schulungen zu videobasierten Aufgaben, sodass Ihr Modell lernen kann, wie es Fragen zu Videoinhalten analysiert und beantwortet.

## Datenformat für das Verständnis von Videos

Zu den Trainingsdaten für das Verständnis von Videos gehören Videoreferenzen in den Inhaltsblöcken für den Nutzer. Dabei lernt das Modell, anhand von Videoinhalten Informationen und Argumentation zu extrahieren.

## Eingabe als Beispiel

```
{
 "schemaVersion": "bedrock-conversation-2024",
 "messages": [
 {
 "role": "user",
```

```
 "content": [
 {
 "text": "What are the ways in which a customer can experience issues during
checkout on Amazon?"
 },
 {
 "video": {
 "format": "mp4",
 "source": {
 "s3Location": {
 "uri": "s3://my-bucket-name/path/to/videos/
customer_service_debugging.mp4",
 "bucketOwner": "123456789012"
 }
 }
 }
 }
],
 {
 "role": "assistant",
 "content": [
 {
 "reasoningContent": {
 "reasoningText": {
 "text": "I need to find the relevant section in the video to answer the
question."
 }
 }
 },
 {
 "text": "Customers can experience issues with 1. Data entry, 2. Payment
methods, 3. Connectivity while placing the order. Which one would you like to dive
into?"
 }
]
 }
]
}
```

## Einschränkungen beim Videoverständnis

| Einschränkung           | Details                                                                                                                             |
|-------------------------|-------------------------------------------------------------------------------------------------------------------------------------|
| Maximale Videogröße     | 50 MB                                                                                                                               |
| Maximale Videodauer     | 15 Minuten                                                                                                                          |
| Videos pro Probe        | Pro Probe ist nur ein Video erlaubt. Mehrere Videos in derselben Stichprobe werden nicht unterstützt                                |
| Mischen von Modalitäten | Ein Beispiel kann Video und Text enthalten, Video kann jedoch nicht mit anderen Modalitäten (Bildern, Dokumenten) kombiniert werden |

## Unterstützte Videoformate

- MOV
- MKV
- MP4

## Bewährte Methoden zum Verständnis von Videos

- Halten Sie die Videos kurz und konzentrieren Sie sich auf den Inhalt, der für Ihre Aufgabe relevant ist
- Stellen Sie sicher, dass die Videoqualität ausreicht, damit das Modell aussagekräftige Informationen extrahieren kann
- Stellen Sie klare Fragen, die sich auf bestimmte Aspekte des Videoinhalts beziehen
- Fügen Sie verschiedene Beispiele hinzu, die verschiedene Videotypen und Fragenformate abdecken

## Argumentationsmodus versus Modus ohne Argumentation

### Inhalt des Denkens verstehen

Der Inhalt des Arguments (auch genannt chain-of-thought) erfasst die Zwischenschritte des Modells beim Denken, bevor eine endgültige Antwort generiert wird. Verwenden `assistant` Sie wiederum das `reasoningContent` Feld, um diese Argumentationsspuren einzufügen.



## Wie wird der Verlust berechnet

- Mit Argumentationsinhalt — Der Trainingsverlust umfasst sowohl Argumentationstoken als auch Token für das Endergebnis
- Ohne Inhalt zum Argumentieren — Der Trainingsverlust wird nur anhand der endgültigen Ausgangstoken berechnet

Sie können mehrere Runden des Assistenten in Konversationen mit `reasoningContent` mehreren Runden einbeziehen.

## Richtlinien zur Formatierung

- Verwenden Sie Klartext, um Inhalte zu begründen
- Vermeiden Sie Markup-Tags wie `<thinking>` und `</thinking>` sofern dies nicht ausdrücklich für Ihre Aufgabe erforderlich ist
- Stellen Sie sicher, dass der Inhalt der Argumentation klar und relevant für den Problemlösungsprozess ist

## Wann sollte der Argumentationsmodus aktiviert werden

Stellen Sie `reasoning_enabled: true` in Ihrer Trainingskonfiguration ein, wann:

- Deine Trainingsdaten enthalten Tokens zur Argumentation
- Sie möchten, dass das Modell Denkansätze generiert, bevor die endgültigen Ergebnisse erstellt werden
- Sie benötigen eine verbesserte Leistung bei komplexen Argumentationsaufgaben

Das Training von Nova mit `reasoning_enabled = true` einem Datensatz ohne Argumentation ist zulässig. Dies kann jedoch dazu führen, dass das Modell seine Argumentationsfähigkeit verliert, da Nova in erster Linie lernt, die in den Daten enthaltenen Antworten zu generieren, ohne Argumentation anzuwenden. Wenn Sie Nova anhand eines Datensatzes ohne Argumentation trainieren möchten, aber dennoch erwarten, dass bei Inferenz Argumentation stattfindet, können Sie das Argumentieren während des Trainings () `reasoning_enabled = false` deaktivieren, es aber für Inferenz aktivieren. Dieser Ansatz ermöglicht zwar die Verwendung von Argumenten zum Zeitpunkt der Inferenz, garantiert jedoch keine bessere Leistung im Vergleich zu Schlussfolgerungen ohne Argumentation. Generell sollten Sie Argumentation sowohl für Training als auch für Folgerungen

aktivieren, wenn Sie Datensätze mit Argumentation verwenden, und deaktivieren Sie sie für beide, wenn Sie Datensätze ohne Argumentation verwenden.

Stellen Sie ein, wann: `reasoning_enabled: false`

- In deinen Trainingsdaten gibt es keine Argumentationsnachweise
- Sie trainieren an einfachen Aufgaben, für die keine expliziten Argumentationsschritte erforderlich sind
- Sie möchten die Geschwindigkeit optimieren und die Token-Nutzung reduzieren

## Generierung von Argumentationsdaten

Wenn es Ihrem Datensatz an Argumentationsspuren mangelt, können Sie diese mit einem Modell, das Argumentation ermöglicht, wie Nova Premier, erstellen. Stellen Sie dem Modell Ihre Input-Output-Paare zur Verfügung und erfassen Sie dessen Argumentationsprozess, um einen mit Argumenten erweiterten Datensatz zu erstellen.

## Verwendung von Argumentationstoken für das Training

Beim Training mit aktiviertem Argumentationsmodus lernt das Modell, internes Denken von der endgültigen Antwort zu trennen. Der Trainingsprozess:

- Organisiert Daten als Tripel: Eingabe, Argumentation und Antwort
- Optimiert mithilfe von standardmäßigen Verlusten bei der Vorhersage des nächsten Tokens sowohl bei Argumentations- als auch bei Antwort-Tokens
- Ermutigt das Modell, intern zu argumentieren, bevor Antworten generiert werden

## Inhalte zum effektiven Denken

Hochwertige Inhalte zum Argumentieren sollten Folgendes beinhalten:

- Zwischengedanken und Analysen
- Logische Ableitungen und Inferenzschritte
- Step-by-step Ansätze zur Problemlösung
- Explizite Zusammenhänge zwischen Schritten und Schlussfolgerungen

Dies hilft dem Modell, die Fähigkeit zu entwickeln, „erst nachzudenken, bevor man antwortet“.

## Richtlinien für die Vorbereitung von Datensätzen

### Größe und Qualität

- Empfohlene Größe — 2.000-10.000 Proben
- Mindestanzahl der Proben — 200
- Priorität — Qualität vor Quantität. Stellen Sie sicher, dass die Beispiele korrekt und gut kommentiert sind
- Abstimmung der Anwendungen — Der Datensatz sollte Ihre Anwendungsfälle in der Produktion genau widerspiegeln

### Vielfalt

Nennen Sie verschiedene Beispiele, die:

- Decken Sie das gesamte Spektrum der erwarteten Eingaben ab
- Stellen Sie verschiedene Schwierigkeitsgrade dar
- Schließe Sonderfälle und Varianten mit ein
- Vermeiden Sie eine Überanpassung an schmale Muster

### Formatierung der Ausgabe

Geben Sie das gewünschte Ausgabeformat in den Antworten des Assistenten eindeutig an:

- JSON-Strukturen
- Tabellen
- CSV-Format
- Benutzerdefinierte Formate, die für Ihre Anwendung spezifisch sind

### Multi-turn-Konversationen

Beachten Sie bei Multiturn-Datensätzen Folgendes:

- Der Verlust wird nur für die Züge des Assistenten berechnet, nicht für die Züge eines Benutzers
- Jede Antwort des Assistenten sollte korrekt formatiert sein
- Sorgen Sie für Konsistenz in allen Gesprächsrunden

## Checkliste für Qualität

- Ausreichende Datensatzgröße (2K-10.000 Stichproben)
- Vielfältige Beispiele für alle Anwendungsfälle
- Klare, konsistente Ausgabeformatierung
- Präzise Beschriftungen und Anmerkungen
- Repräsentativ für Produktionsszenarien
- Frei von Widersprüchen oder Unklarheiten

## Hochladen Ihrer Daten

Datensätze sollten in einen Bucket hochgeladen werden, auf den Trainingsjobs zugegriffen werden kann. SageMaker Informationen zum Einstellen der richtigen Berechtigungen finden Sie unter [Voraussetzungen](#).

## Einen Ausbildungsjob beginnen

### Hyperparameter auswählen und das Rezept aktualisieren

Das Setup für Nova 2.0 ist weitgehend das gleiche wie für Nova 1.0. Sobald die Eingabedaten auf S3 hochgeladen wurden, verwenden Sie das Rezept aus dem Ordner [SageMaker HyperPod Rezepte](#) im Ordner Fine Tuning. Für Nova 2.0 sind im Folgenden einige der wichtigsten Hyperparameter aufgeführt, die Sie je nach Anwendungsfall aktualisieren können. Das Folgende ist ein Beispiel für das Nova 2.0 SFT PEFT-Rezept. Verwenden Sie den Container-Image-URI, `708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-TJ-SFT-V2-latest` um einen SFT-Feintuning-Job auszuführen.

Bitte verwenden Sie Version 2.254.1 von SageMaker AI PySDK, um die strikte Kompatibilität mit dem Nova-Training zu gewährleisten. Ein Upgrade des SDK auf Version 3.0 wird zu grundlegenden Änderungen führen. Support für Version 3 von SageMaker AI PySDK ist in Kürze verfügbar.

## Beispieleingabe

```
!pip install sagemaker==2.254.1
```

```
run:
 name: {peft_recipe_job_name}
 model_type: amazon.nova-2-lite-v1:0:256k
 model_name_or_path: {peft_model_name_or_path}
```

```

data_s3_path: {train_dataset_s3_path} # SageMaker HyperPod (SMHP) only and not
compatible with SageMaker Training jobs. Note replace my-bucket-name with your real
bucket name for SMHP job
 replicas: 4 # Number of compute instances for training, allowed
values are 4, 8, 16, 32
 output_s3_path: "" # Output artifact path (Hyperpod job-specific; not
compatible with standard SageMaker Training jobs). Note replace my-bucket-name with
your real bucket name for SMHP job

training_config:
 max_steps: 10 # Maximum training steps. Minimal is 4.
 save_steps: 10 # How many training steps the checkpoint will be
saved. Should be less than or equal to max_steps
 save_top_k: 1 # Keep top K best checkpoints. Note supported only
for SageMaker HyperPod jobs. Minimal is 1.
 max_length: 32768 # Sequence length (options: 8192, 16384, 32768
[default], 65536)
 global_batch_size: 32 # Global batch size (options: 32, 64, 128)
 reasoning_enabled: true # If data has reasoningContent, set to true;
otherwise False

 lr_scheduler:
 warmup_steps: 15 # Learning rate warmup steps. Recommend 15% of
max_steps
 min_lr: 1e-6 # Minimum learning rate, must be between 0.0 and 1.0

 optim_config: # Optimizer settings
 lr: 1e-5 # Learning rate, must be between 0.0 and 1.0
 weight_decay: 0.0 # L2 regularization strength, must be between 0.0
and 1.0
 adam_beta1: 0.9 # Exponential decay rate for first-moment estimates,
must be between 0.0 and 1.0
 adam_beta2: 0.95 # Exponential decay rate for second-moment
estimates, must be between 0.0 and 1.0

 peft: # Parameter-efficient fine-tuning (LoRA)
 peft_scheme: "lora" # Enable LoRA for PEFT
 lora_tuning:
 alpha: 64 # Scaling factor for LoRA weights (options: 32, 64,
96, 128, 160, 192),
 lora_plus_lr_ratio: 64.0

```

Das Rezept enthält auch weitgehend dieselben Hyperparameter wie Nova 1.0. Die bemerkenswerten Hyperparameter sind:

- `max_steps`— Die Anzahl der Schritte, für die Sie den Job ausführen möchten. Im Allgemeinen gilt für eine Epoche (ein Durchlauf durch Ihren gesamten Datensatz) die Anzahl der Schritte = Anzahl der Datenstichproben/globale Batchgröße. Je größer die Anzahl der Schritte und je kleiner Ihre globale Batchgröße ist, desto länger dauert die Ausführung des Jobs.
- `reasoning_enabled`— Steuert den Argumentationsmodus für Ihren Datensatz. Optionen:
  - `true`: Aktiviert den Argumentationsmodus (entspricht hohem Argumentationsvermögen)
  - `false`: Deaktiviert den Argumentationsmodus

Hinweis: Bei SFT gibt es keine detaillierte Kontrolle über den Grad des Argumentationsaufwands. Die Einstellung `reasoning_enabled: true` ermöglicht die volle Argumentationsfähigkeit.

- `peft.peft_scheme`— Die Einstellung „Lora“ ermöglicht eine PEFT-basierte Feinabstimmung. Wenn Sie es auf Null setzen (keine Anführungszeichen), wird die Full-Rank-Feinabstimmung aktiviert.

## Starte den Trainingsjob

```
from sagemaker.pytorch import PyTorch

define OutputDataConfig path
if default_prefix:
 output_path = f"s3://{bucket_name}/{default_prefix}/{sm_training_job_name}"
else:
 output_path = f"s3://{bucket_name}/{sm_training_job_name}"

output_kms_key = "<KMS key arn to encrypt trained model in Amazon-owned S3 bucket>" #
 optional, leave blank for Amazon managed encryption

recipe_overrides = {
 "run": {
 "replicas": instance_count, # Required
 "output_s3_path": output_path
 },
}

estimator = PyTorch(
 output_path=output_path,
 base_job_name=sm_training_job_name,
```

```

 role=role,
 disable_profiler=True,
 debugger_hook_config=False,
 instance_count=instance_count,
 instance_type=instance_type,
 training_recipe=training_recipe,
 recipe_overrides=recipe_overrides,
 max_run=432000,
 sagemaker_session=sagemaker_session,
 image_uri=image_uri,
 output_kms_key=output_kms_key,
 tags=[
 {'Key': 'model_name_or_path', 'Value': model_name_or_path},
]
)

print(f"\nsm_training_job_name:\n{sm_training_job_name}\n")
print(f"output_path:\n{output_path}")

```

```

from sagemaker.inputs import TrainingInput

train_input = TrainingInput(
 s3_data=train_dataset_s3_path,
 distribution="FullyReplicated",
 s3_data_type="Converse",
)

estimator.fit(inputs={"validation": val_input}, wait=False)

```

### Note

Die Weitergabe eines Validierungsdatensatzes wird für die überwachte Feinabstimmung von Nova 2.0 nicht unterstützt.

Um den Job zu beginnen:

- Aktualisieren Sie das Rezept mit Ihren Datensatzpfaden und Hyperparametern
- Führen Sie die angegebenen Zellen im Notizbuch aus, um den Trainingsjob abzusenden

Das Notizbuch verarbeitet die Auftragsübermittlung und ermöglicht die Statusverfolgung.

## Vorbereitung der Daten für die multimodale Feinabstimmung

### Important

Bevor Sie mit der Vorbereitung Ihres Datensatzes beginnen, stellen Sie sicher, dass die überwachte Feinabstimmung (SFT) der richtige Ansatz für Ihren Anwendungsfall ist. SFT bringt dem Modell neue Verhaltensweisen, Antwortformate und Denkmuster bei. Es vermittelt dem Modell kein neues Faktenwissen. Wenn Ihr primäres Ziel darin besteht, domänenspezifische Fakten, Terminologie oder Wissen einzuführen, das das Modell noch nicht erkannt hat, sollten Sie eine Retrieval-Augmented Generation (RAG) in Betracht ziehen, um diesen Kontext zum Zeitpunkt der Inferenz bereitzustellen. Hinweise zur Wahl zwischen SFT, Reinforcement Fine-Tuning (RFT) und RAG finden Sie unter [Amazon Nova-Anpassung bei SageMaker Schulungsjobs](#)

Im Folgenden finden Sie Richtlinien und Anforderungen für die Vorbereitung von Daten für die Feinabstimmung von Verständnismodellen:

1. Die Mindestdatengröße für die Feinabstimmung hängt von der Aufgabe ab (d. h. komplex oder einfach), jedoch empfehlen wir Ihnen, mindestens 100 Beispiele für jede Aufgabe zu verwenden, die das Modell lernen soll.
2. Wir empfehlen, Ihren optimierten Prompt sowohl während des Trainings als auch während der Inferenz in einer Zero-Shot-Umgebung zu verwenden, um optimale Ergebnisse zu erzielen.
3. Trainings- und Validierungsdatensätze müssen JSONL-Dateien sein, wobei jede Zeile ein JSON-Objekt darstellt, das einem Datensatz entspricht. Diese Dateinamen dürfen nur aus alphanumerischen Zeichen, Unterstrichen, Bindestrichen, Schrägstrichen und Punkten bestehen.
4. Bild- und Video-Einschränkungen
  - a. Der Datensatz darf keine unterschiedlichen Medienmodalitäten enthalten. Das heißt, der Datensatz kann entweder Text mit Bildern oder Text mit Videos sein.
  - b. Ein Beispiel (einzelner Datensatz in Nachrichten) kann mehrere Bilder enthalten
  - c. Ein Beispiel (einzelner Datensatz in Nachrichten) kann nur 1 Video enthalten
5. `schemaVersion` kann ein beliebiger Zeichenfolgenwert sein
6. Die (Optional) `system`-Runde kann ein vom Kunden bereitgestellter benutzerdefinierter System-Prompt sein.
7. Unterstützte Rollen sind `user` und `assistant`.



8. Die erste Runde in messages sollte immer mit "role": "user" beginnen. Die letzte Runde ist die Antwort des Bots, gekennzeichnet durch "role": "assistant"
9. `image.source.s3Location.uri` und `video.source.s3Location.uri` müssen für Amazon Bedrock zugänglich sein.
10. Ihre Amazon-Bedrock-Servicerolle muss in der Lage sein, auf die Bilddateien in Amazon S3 zuzugreifen. Weitere Informationen über die Gewährung von Zugriffsrechten finden Sie unter [Eine Servicerolle für die Modellanpassung erstellen](#)
11. Die Bilder oder Videos müssen sich im selben Amazon-S3-Bucket wie Ihr Datensatz befinden. Wenn sich Ihr Datensatz beispielsweise in `s3://amzn-s3-demo-bucket/train/train.jsonl` befindet, müssen Ihre Bilder oder Videos in `s3://amzn-s3-demo-bucket` gespeichert sein
12. Die Begriffe `User:`, `Bot:`, `Assistant:`, `System:`, `<image>`, `<video>` und `[EOS]` sind reservierte Schlüsselwörter. Wenn eine Benutzer- oder Systemaufforderung mit einem dieser Schlüsselwörter beginnt oder diese Schlüsselwörter irgendwo in der Eingabeaufforderung vorkommen, schlägt Ihre Trainingsaufgabe aufgrund von Datenproblemen fehl. Wenn Sie diese Schlüsselwörter für Ihren Anwendungsfall verwenden müssen, müssen Sie sie durch andere Stichwörter mit ähnlicher Bedeutung ersetzen, damit Ihre Schulung fortgesetzt werden kann.

#### Note

Um Ihren Datensatz zu validieren, bevor Sie einen Job zur Feinabstimmung einreichen, können Sie das auf GitHub verfügbare [Datensatzvalidierungsskript](#) verwenden.

## Entwerfen effektiver Schulungsbeispiele

Ihre Trainingsdaten sollten das Verhalten zeigen, das das Modell zeigen soll. SFT bringt dem Modell bei, wie es reagieren soll, und nicht, was es wissen soll. Wenn Sie Trainingsbeispiele in erster Linie erstellen, um Ihnen Faktenwissen zu vermitteln (zum Beispiel „Was bedeutet Fehlercode E-45?“ mit der Antwort „E-45 weist auf ein Sensor-Timeout hin“) sollten Sie sich überlegen, ob RAG oder Prompt Engineering ohne Feinabstimmung dasselbe Ergebnis erzielen könnten.

Beachten Sie bei der Konvertierung von Quelldaten in das Konversationsformat die folgenden Prinzipien:

1. Beginnen Sie mit echten Benutzeranfragen. Write-User-Wendungen, die widerspiegeln, wie Endbenutzer das Modell in der Produktion tatsächlich aufrufen werden. Vermeiden Sie künstliche oder zu vereinfachte Fragen, die nicht den tatsächlichen Nutzungsmustern entsprechen.
2. Schreiben Sie Antworten von Assistenten nach Goldstandard. Jede Runde des Assistenten sollte die ideale Antwort sein, die das Modell erzeugen soll — korrekt, gut formatiert und in Ton und Struktur in allen Beispielen einheitlich.
3. Verwenden Sie die Systemaufforderung strategisch. Platzieren Sie persistente Anweisungen wie Ausgabeformat, Persona und Domänenkontext nacheinander im System. Verwenden Sie sowohl beim Training als auch bei der Inferenz dieselbe Systemaufforderung, um die besten Ergebnisse zu erzielen.
4. Konzentrieren Sie sich bei den Beispielen auf eine Fähigkeit pro Stichprobe. Wenn Sie das Modell zum Klassifizieren, Beantworten von Fragen und Zusammenfassen benötigen, erstellen Sie separate Beispielsätze für jede Fähigkeit, anstatt mehrere Fähigkeiten in einer einzigen Stichprobe zu kombinieren.
5. Priorisieren Sie Qualität vor Quantität. Ein paar hundert qualitativ hochwertige, konsistente Beispiele übertreffen in der Regel Tausende von lauten oder widersprüchlichen Beispielen. Deduplizieren und überprüfen Sie Ihre Daten vor dem Training.

## Gängige Muster für die Datentransformation

Die folgenden Muster veranschaulichen, wie gängige Unternehmensdatenformate in effektive SFT-Schulungsbeispiele umgewandelt werden können.

### Muster 1: Strukturierte Datensätze zur Klassifizierung oder Suche

Wenn es sich bei Ihren Quelldaten um eine Tabelle oder Datenbank mit Datensätzen mit Feldern wie `issuecause`, und `handeltresolution`, stellen Sie jeden Datensatz als Benutzerfrage mit den entsprechenden Eingabefeldern und der Antwort des Assistenten als Zielausgabefeldern ein.

```
// train.jsonl
{
 "schemaVersion": "bedrock-conversation-2024",
 "system": [
 {
 "text": "You are a technical support assistant. Given an issue description, identify the most likely root cause and recommended resolution."
 }
],

```

```

"messages": [
 {
 "role": "user",
 "content": [
 {
 "text": "A user reports: 'Application crashes on startup after the latest update.' What is the likely cause and resolution?"
 }
]
 },
 {
 "role": "assistant",
 "content": [
 {
 "text": "Cause: Incompatible configuration file from the previous version.
\nResolution: Delete the local configuration cache and restart the application to regenerate default settings."
 }
]
 }
]
}

```

## Muster 2: Von hierarchischen oder taxonomischen Daten bis hin zu strukturierten Fragen und Antworten

Wenn es sich bei Ihren Quelldaten um eine Codehierarchie oder Taxonomie wie Produktkategoriebäume oder Klassifikationssysteme handelt, generieren Sie Fragen, die das Modell bitten, sich in der Hierarchie zurechtzufinden. Beziehen Sie den Klassifizierungskontext in die Systemaufforderung oder in die Benutzerrunde ein.

```

// train.jsonl
{
 "schemaVersion": "bedrock-conversation-2024",
 "system": [
 {
 "text": "You are a product catalog assistant. Answer questions about product categories and classifications accurately."
 }
],
 "messages": [
 {
 "role": "user",

```

```

 "content": [
 {
 "text": "What top-level category does product code 'EL-4520' belong to, and what subcategories does it include?"
 }
],
 {
 "role": "assistant",
 "content": [
 {
 "text": "Product code EL-4520 belongs to the Electronics category. It includes the subcategories: Audio Equipment, Portable Speakers, and Wireless Accessories."
 }
]
 }
]
}

```

### Muster 3: Von den prozeduralen Dokumenten zum Anleitungsdialog

Wenn Ihre Quelldaten aus Standardarbeitsanweisungen, Runbooks oder schrittweisen Anleitungen bestehen, konvertieren Sie Verfahren in aufgabenorientierte Fragen. Der Benutzer fragt, wie eine Aufgabe ausgeführt werden soll, und der Assistent stellt die Schritte in einem konsistenten Format bereit.

```

// train.jsonl
{
 "schemaVersion": "bedrock-conversation-2024",
 "system": [
 {
 "text": "You are an IT operations assistant. Provide step-by-step instructions based on approved runbooks and standard operating procedures."
 }
],
 "messages": [
 {
 "role": "user",
 "content": [
 {
 "text": "How do I reset a user's multi-factor authentication when they have lost access to their device?"
 }
]
 }
]
}

```

```
 }
]
},
{
 "role": "assistant",
 "content": [
 {
 "text": "Follow these steps to reset a user's multi-factor authentication:
\n1. Verify the user's identity using the approved verification procedure.\n2. Disable
the existing MFA configuration in the identity management console.\n3. Generate a new
temporary access code and send it to the user's verified email.\n4. Instruct the user
to log in with the temporary code and re-enroll their new device.\n5. Confirm the new
MFA device is working by requesting a test authentication.\n6. Document the reset in
the support ticket."
 }
]
}
]
```

#### Note

Wenn in den Mustern 1 und 2 der sachliche Inhalt (wie Codes, Kategorien oder Auflösungen) nicht bereits in den Daten des Modells vor dem Training enthalten ist, sollten Sie in Erwägung ziehen, RAG zu verwenden, um diese Informationen zum Zeitpunkt der Inferenz bereitzustellen, anstatt sich ausschließlich auf SFT zu verlassen, um sie auswendig zu lernen. SFT ist am effektivsten, wenn es darum geht, dem Modell das Antwortformat und das Argumentationsmuster beizubringen, während RAG die faktische Grundlage übernimmt.

## Themen

- [Beispieldatensatzformate](#)
- [Einschränkungen für Datensätze](#)

## Beispieldatensatzformate

Die folgenden Beispieldatensatzformate bieten Ihnen eine Orientierungshilfe.

## Text-only benutzerdefiniertes Format für die Feinabstimmung

Das folgende Beispiel dient ausschließlich der benutzerdefinierten Feinabstimmung von Text.

```
// train.jsonl
{
 "schemaVersion": "bedrock-conversation-2024",
 "system": [
 {
 "text": "You are a digital assistant with a friendly personality"
 }
],
 "messages": [
 {
 "role": "user",
 "content": [
 {
 "text": "What is the capital of Mars?"
 }
]
 },
 {
 "role": "assistant",
 "content": [
 {
 "text": "Mars does not have a capital. Perhaps it will one day."
 }
]
 }
]
}
```

## Benutzerdefiniertes Feinabstimmungsformat für einzelne Bilder

Das folgende Beispiel dient der benutzerdefinierten Feinabstimmung von Text und einem einzelnen Bild.

```
// train.jsonl{
 "schemaVersion": "bedrock-conversation-2024",
 "system": [{
 "text": "You are a smart assistant that answers questions respectfully"
 }],
 "messages": [{
```

```

 "role": "user",
 "content": [{
 "text": "What does the text in this image say?"
 },
 {
 "image": {
 "format": "png",
 "source": {
 "s3Location": {
 "uri": "s3://your-bucket/your-path/your-image.png",
 "bucketOwner": "your-aws-account-id"
 }
 }
 }
 }
],
},
{
 "role": "assistant",
 "content": [{
 "text": "The text in the attached image says 'LOL'."
 }]
}
]
}

```

## Benutzerdefiniertes Feinabstimmungsformat für Videos

Das folgende Beispiel dient der benutzerdefinierten Feinabstimmung von Text und Video.

```

{
 "schemaVersion": "bedrock-conversation-2024",
 "system": [{
 "text": "You are a helpful assistant designed to answer questions crisply and to the point"
 }],
 "messages": [{
 "role": "user",
 "content": [{
 "text": "How many white items are visible in this video?"
 },
 {
 "video": {
 "format": "mp4",

```

```

 "source": {
 "s3Location": {
 "uri": "s3://your-bucket/your-path/your-video.mp4",
 "bucketOwner": "your-aws-account-id"
 }
 }
 },
 {
 "role": "assistant",
 "content": [{
 "text": "There are at least eight visible items that are white"
 }]
 }
]
}

```

## Einschränkungen für Datensätze

Amazon Nova wendet die folgenden Einschränkungen auf Modellanpassungen für Verständnismodelle an.

| Modell      | Minimale Anzahl von Beispielen | Maximale Anzahl von Beispielen | Kontextlänge |
|-------------|--------------------------------|--------------------------------|--------------|
| Nova 2 Lite | 8                              | 20 000                         | 32 000       |

## Bild- und Video-Einschränkungen

|                                 |             |
|---------------------------------|-------------|
| Maximale Anzahl an Bildern      | 10/sample   |
| Maximale Größe von Bilddateien  | 10 MB       |
| Maximale Anzahl von Videos      | 1/sample    |
| Maximales Video length/duration | 90 Sekunden |
| Maximale Größe von Videodateien | 50 MB       |



## Unterstützte Medienformate

- Bild – png, jpeg, gif, webp
- Video – mov, mkv, mp4, webm

## Verstärkung Fine-Tuning (RFT) mit Amazon Nova-Modellen

### -Übersicht

#### Was ist RFT?

Reinforcement Fine-Tuning (RFT) verbessert die Modellleistung, indem das Training anhand von Feedbacksignalen — messbaren Ergebnissen oder Belohnungen, die anzeigen, wie gut das Modell abgeschnitten hat — und nicht anhand exakter richtiger Antworten trainiert wird. Im Gegensatz zur überwachten Feinabstimmung (SFT), die aus Input-Output-Paaren lernt, verwendet RFT Belohnungsfunktionen, um Modellantworten zu bewerten, und optimiert das Modell iterativ, um diese Belohnungen zu maximieren. Dieser Ansatz eignet sich hervorragend, wenn es schwierig ist, den exakt richtigen Output zu definieren, aber Sie können die Antwortqualität zuverlässig messen.

#### Wann sollte RFT verwendet werden

Verwenden Sie RFT, wenn Sie klare, messbare Erfolgskriterien definieren können, es aber schwierig ist, exakt korrekte Ergebnisse für das Training bereitzustellen. RFT ist ideal für:

- Aufgaben, bei denen die Qualität subjektiv oder vielfältig ist (kreatives Schreiben, Codeoptimierung, komplexes Denken)
- Szenarien mit mehreren gültigen Lösungen, bei denen einige eindeutig besser sind als andere
- Anwendungen, die iterative Verbesserungen, Personalisierung oder die Einhaltung komplexer Geschäftsregeln erfordern
- Fälle, in denen das Sammeln hochwertiger, beschrifteter Beispiele teuer oder unpraktisch ist

#### Beste Anwendungsfälle

RFT zeichnet sich in Bereichen aus, in denen die Ausgabequalität objektiv gemessen werden kann, es jedoch schwierig ist, optimale Antworten im Voraus zu definieren:

- Mathematische Problemlösung und Codegenerierung
- Wissenschaftliches Denken und strukturierte Datenanalyse

- Aufgaben, die eine schrittweise Argumentation oder eine mehrstufige Problemlösung erfordern
- Anwendungen, die mehrere Ziele (Genauigkeit, Effizienz, Stil) unter einen Hut bringen
- Szenarien, in denen der Erfolg programmatisch anhand von Ausführungsergebnissen oder Leistungskennzahlen verifiziert werden kann

## Unterstützte Modelle

### Nova Lite 2.0

## Überblick über das Datenformat

[RFT-Trainingsdaten müssen dem OpenAI Fine-Tuning Reinforcement-Format entsprechen.](#) Jedes Trainingsbeispiel ist ein JSON-Objekt, das Folgendes enthält:

- Ein `messages` Array mit abwechselnden Konversationen `system` und Rollen `user`
- Ein `reference_answer` Feld, das die erwarteten Ergebnis- oder Bewertungskriterien für die Berechnung der Belohnung enthält

## Derzeitige Einschränkungen

- Nur Text

## Beispiele für Datenformate

Jedes Beispiel sollte sich in einer einzigen Zeile in Ihrer JSONL-Datei befinden, mit einem JSON-Objekt pro Zeile.

### Chemistry problem

```
{
 "id": "chem-01",
 "messages": [
 {
 "role": "system",
 "content": "You are a helpful chemistry assistant"
 },
 {
 "role": "user",
 "content": "Calculate the molecular weight of caffeine (C8H10N4O2)"
 }
]
}
```

```
],
"reference_answer": {
 "molecular_weight": 194.19,
 "unit": "g/mol",
 "calculation": "8(12.01) + 10(1.008) + 4(14.01) + 2(16.00) = 194.19"
}
}
```

## Math problem

```
{
 "id": "sample-001", // Optional
 "messages": [
 {
 "role": "system",
 "content": "You are a math tutor"
 },
 {
 "role": "user",
 "content": "Solve: $2x + 5 = 13$ "
 }
],
 "reference_answer": {
 "solution": " $x = 4$ ",
 "steps": [" $2x = 13 - 5$ ", " $2x = 8$ ", " $x = 4$ "]
 }
}
```

## Code problem

```
{
 "id": "code-002",
 "messages": [
 {
 "role": "system",
 "content": "You are a helpful programming assistant"
 },
 {
 "role": "user",
 "content": "Write a Python function that reverses a string without using built-in reverse methods"
 }
],
}
```

```

"reference_answer": {
 "code": "def reverse_string(s): \n result = '' \n for i in range(len(s)
- 1, -1, -1): \n result += s[i] \n return result",
 "test_cases": [
 {
 "input": "hello",
 "expected_output": "olleh"
 },
 {
 "input": "",
 "expected_output": ""
 },
 {
 "input": "a",
 "expected_output": "a"
 },
 {
 "input": "Python123",
 "expected_output": "321nohtyP"
 }
],
 "all_tests_pass": true
}

```

Das `reference_answer` Feld enthält die erwarteten Ausgabe- oder Bewertungskriterien, anhand derer Ihre Belohnungsfunktion die Antwort des Modells bewertet. Es ist nicht auf strukturierte Ausgaben beschränkt — es kann jedes Format enthalten, das Ihrer Belohnungsfunktion bei der Bewertung der Qualität hilft.

## Empfehlungen zur Größe von Datensätzen

### Ausgangspunkt

- Mindestens 100 Trainingsbeispiele
- Mindestens 100 Bewertungsbeispiele

### Evaluation-first Ansatz

Bevor Sie in groß angelegte RFT-Schulungen investieren, sollten Sie die Ausgangsleistung Ihres Modells bewerten:

- Hohe Leistung (> 95% Belohnung) — RFT ist möglicherweise unnötig — Ihr Modell schneidet bereits gut ab
- Sehr schlechte Leistung (Prämie von 0%) — Wechseln Sie zuerst zu SFT, um die grundlegenden Funktionen zu verbessern
- Mäßige Leistung — RFT ist wahrscheinlich angemessen

Wenn Sie mit einem kleinen Datensatz beginnen, können Sie:

- Bestätigen Sie, dass Ihre Belohnungsfunktion fehlerfrei ist
- Stellen Sie sicher, dass RFT der richtige Ansatz für Ihren Anwendungsfall ist
- Identifizieren und beheben Sie Probleme frühzeitig
- Testen Sie den Workflow, bevor Sie ihn skalieren

Nach der Validierung können Sie auf größere Datensätze expandieren, um die Leistung weiter zu verbessern.

## Merkmale effektiver Trainingsdaten

### Klarheit und Kohärenz

Gute RFT-Beispiele erfordern klare, eindeutige Eingabedaten, die eine genaue Berechnung der Belohnung für verschiedene Modellergebnisse ermöglichen. Vermeiden Sie Rauschen in Ihren Daten, einschließlich:

- Inkonsistente Formatierung
- Widersprüchliche Bezeichnungen oder Anweisungen
- Mehrdeutige Aufforderungen
- Widersprüchliche Referenzantworten

Jede Unklarheit führt den Trainingsprozess in die Irre und führt dazu, dass das Modell unbeabsichtigte Verhaltensweisen erlernt.

### Diversität

Ihr Datensatz sollte die gesamte Vielfalt der Anwendungsfälle in der Produktion erfassen, um eine robuste Leistung unter realen Bedingungen zu gewährleisten. Enthalten sind:

- Verschiedene Eingabeformate und Sonderfälle
- Bilden Sie die tatsächlichen Nutzungsmuster in der Produktion anhand von Protokollen und Benutzeranalysen ab
- Sehen Sie sich verschiedene Benutzertypen, geografische Regionen und saisonale Schwankungen an
- Schließe Schwierigkeitsgrade von einfachen bis hin zu komplexen Problemen ein

### Überlegungen zur Belohnungsfunktion

Gestalten Sie Ihre Belohnungsfunktion für effizientes Training:

- Innerhalb von Sekunden (nicht Minuten) ausführen
- Effektive Parallelisierung mit Lambda
- Geben Sie konsistente, zuverlässige Ergebnisse zurück
- Gehen Sie elegant mit verschiedenen Arten von Modellausgaben um

Schnelle, skalierbare Belohnungsfunktionen ermöglichen schnelle Iterationen und kostengünstiges Experimentieren.

### Zusätzliche Eigenschaften

Das RFT-Datenformat unterstützt benutzerdefinierte Felder, die über die grundlegenden Schemaanforderungen (`messagesand`) hinausgehen. `reference_answer` Dank dieser Flexibilität können Sie alle zusätzlichen Daten hinzufügen, die Ihre Prämienfunktion für eine korrekte Auswertung benötigt.

#### Note

Sie müssen dies nicht in Ihrem Rezept konfigurieren — das Datenformat unterstützt grundsätzlich zusätzliche Felder. Füge sie einfach in deine Trainingsdaten-JSON ein und sie werden an deine Belohnungsfunktion im Feld weitergegeben. `metadata`

### Allgemeine zusätzliche Eigenschaften

Beispiele für Metadatenfelder:

- `task_id`— Eindeutige Kennung für die Nachverfolgung

- `difficulty_level`— Indikator für die Komplexität des Problems
- `domain`— Fachgebiet oder Kategorie
- `expected_reasoning_steps`— Anzahl der Lösungsschritte

### Beispiel mit zusätzlichen Eigenschaften

```
{
 "messages": [
 {
 "role": "system",
 "content": "You are a math tutor"
 },
 {
 "role": "user",
 "content": "Solve: $2x + 5 = 13$ "
 }
],
 "reference_answer": {
 "solution": " $x = 4$ ",
 "steps": [" $2x = 13 - 5$ ", " $2x = 8$ ", " $x = 4$ "]
 },
 "task_id": "algebra_001",
 "difficulty_level": "easy",
 "domain": "algebra",
 "expected_reasoning_steps": 3
}
```

Diese zusätzlichen Felder werden während der Auswertung an Ihre Belohnungsfunktion übergeben und ermöglichen so eine ausgeklügelte Bewertungslogik, die auf Ihren speziellen Anwendungsfall zugeschnitten ist.

## Konfiguration des Trainings

### Beispielrezept

```
Note:
This recipe can run on p5.48xlarge, p5e.48xlarge, and p5en.48xlarge instance types.
run:
 name: "my-rft-run" # Unique run name (appears in logs and artifacts).
 model_type: amazon.nova-2-lite-v1:0:256k
```

```

model_name_or_path: nova-lite-2/prod
data_s3_path: s3://<bucket>/<data-file> # Training dataset in JSONL format.
replicas: 4 # Number of total training instances.
generation_replicas: 2 # Number of total instances dedicated
to response generation.
reward_lambda_arn: arn:aws:lambda:<region>:<account-id>:function:<function-name>

MLFlow configs
mlflow_tracking_uri: "" # Required for MLFlow
mlflow_experiment_name: "my-rft-experiment" # Optional for MLFlow. Note: leave this
field non-empty
mlflow_run_name: "my-rft-run" # Optional for MLFlow. Note: leave this field non-empty

SMTJ RFT training configs
training_config:
 max_length: 8192 # Context window (tokens) for inputs
and prompt.
 global_batch_size: 32 # Total samples per optimizer step
across all replicas (16/32/64/128/256).
 reasoning_effort: high # Reasoning mode: high, low, or null
for non-reasoning.

 data:
 shuffle: true # Shuffle training data each epoch.

 rollout: # Controls how responses are generated
for advantage calculation.
 rollout_strategy:
 type: off_policy_async # Asynchronous rollout for higher
throughput.
 age_tolerance: 2 # Maximum policy age before
regeneration.
 advantage_strategy:
 number_generation: 4 # Samples per prompt to estimate
advantages (higher = lower variance but higher cost).
 generator:
 max_new_tokens: 6000 # Cap on tokens generated per sample.
 set_random_seed: true # Seed generation for reproducibility
across runs.
 temperature: 1 # Softmax temperature for sampling.
 rewards:
 preset_reward_function: null # Preset reward functions: exact_match
or null for custom.
 api_endpoint:

```



```

 lambda_arn: arn:aws:lambda:<region>:<account-id>:function:<function-name>
 lambda_concurrency_limit: 12 # Max concurrent Lambda invocations
(throughput vs. throttling).
 lambda_batch_size: 128 # Number of samples per Lambda
invocation.

 trainer:
 max_steps: 2 # Steps to train for. One step =
global_batch_size samples.
 save_steps: 5 # Save a checkpoint every N steps.
 test_steps: 1 # Run validation every N reference
model updates.
 refit_freq: 4 # Frequency of reference model updates.
 clip_ratio_high: 0.2 # PPO clip ratio for policy updates.
 loss_scale: 1.0 # Scaling factor for the policy loss.

 # RL parameters
 ent_coeff: 0.0 # Entropy bonus added to the policy
loss (higher = more exploration).
 kl_loss_coef: 0.0 # Weight on the KL penalty between the
current and reference policy.

 optim_config: # Optimizer settings.
 lr: 1e-6 # Learning rate.
 weight_decay: 0.0 # L2 regularization strength (0.0 to
1.0).
 adam_beta1: 0.9
 adam_beta2: 0.95

 peft: # Parameter-efficient fine-tuning
(LoRA).
 peft_scheme: "lora" # Enable LoRA for PEFT.
 lora_tuning:
 alpha: 64 # LoRA scaling factor.
 lora_plus_lr_ratio: 64.0 # LoRA+ learning rate scaling factor
(0.0 to 100.0).

```

## RFT-Training mit LLM als Richter

### -Übersicht

Große Sprachmodelle (LLMs) werden zunehmend als Richter in Arbeitsabläufen zur Reinforcement-Feinabstimmung (RFT) eingesetzt. Sie liefern automatisierte Belohnungssignale, die als Richtschnur

für die Modelloptimierung dienen. Bei diesem Ansatz bewertet ein LLM die Ergebnisse des Modells anhand bestimmter Kriterien — sei es bei der Bewertung von Korrektheit, Qualität, Stiltreue oder semantischer Gleichwertigkeit — und vergibt Belohnungen, die den Reinforcement-Learning-Prozess vorantreiben.

Dies ist besonders nützlich für Aufgaben, bei denen traditionelle Belohnungsfunktionen programmatisch schwer zu definieren sind, z. B. um festzustellen, ob verschiedene Repräsentationen (wie "1/3,, „0,333" und „ein Drittel“) semantisch gleichwertig sind, oder um nuancierte Eigenschaften wie Kohärenz und Relevanz zu bewerten. Durch die Verwendung von LLM-based Richtern als Belohnungsfunktionen können Sie RFT auf komplexe Bereiche skalieren, ohne dass umfangreiche menschliche Anmerkungen erforderlich sind. Dies ermöglicht eine schnelle Iteration und kontinuierliche Verbesserung Ihrer Modelle für verschiedene Anwendungsfälle, die über herkömmliche Ausrichtungsprobleme hinausgehen.

### Auswahl des Argumentationsmodus

#### Verfügbare Modi

- none — Keine Begründung (lassen Sie das Feld `reasoning_effort` weg)
- niedrig — Minimaler Argumentationsaufwand
- hoch — Maximales Argumentationsvermögen (Standard, wenn `reasoning_effort` angegeben ist)

#### Note

Es gibt keine mittlere Option für RFT. Wenn das Feld `reasoning_effort` in Ihrer Konfiguration nicht vorhanden ist, ist Reasoning deaktiviert. Wenn Argumentation aktiviert ist, sollten Sie den Wert auf 32768 setzen, um die Ausgabe erweiterter Argumentation `max_new_tokens` zu berücksichtigen.

### Wann sollten die einzelnen Modi verwendet werden

Verwenden Sie gute Argumentation für:

- Komplexe analytische Aufgaben
- Mathematische Problemlösung
- Multi-step logische Deduktion
- Aufgaben, bei denen schrittweises Denken einen Mehrwert bietet

Verwenden Sie keine Argumentation (weglassen Sie `reasoning_effort`) oder wenig Argumentation für:

- Einfache sachliche Fragen
- Direkte Klassifizierungen
- Geschwindigkeits- und Kostenoptimierung
- Einfache Beantwortung von Fragen

Kompromisse bei Kosten und Leistung

Höhere Argumentationsmöglichkeiten nehmen zu:

- Trainingszeit und Kosten
- Latenz und Kosten von Inferenzen
- Modellfähigkeit für komplexe Argumentationsaufgaben

Validierung Ihres LLM-Richters

Bevor Sie einen LLM-as-a-judge in der Produktion einsetzen, überprüfen Sie, ob die Bewertungen des Richtermodells dem menschlichen Urteilsvermögen entsprechen. Dies beinhaltet:

- Messen Sie die Übereinstimmungsraten zwischen dem LLM-Richter und menschlichen Gutachtern anhand repräsentativer Stichproben Ihrer Aufgabe
- Sicherstellung, dass die Übereinstimmung zwischen dem LLM und den Menschen die zwischen den Menschen erzielten Übereinstimmungsraten erreicht oder sogar übertrifft
- Identifizierung potenzieller Vorurteile im Richtermodell
- Schaffen Sie die Gewissheit, dass das Belohnungssignal Ihr Modell in die beabsichtigte Richtung lenkt

Dieser Validierungsschritt trägt dazu bei, dass im Rahmen des automatisierten Bewertungsprozesses Modelle erstellt werden, die Ihren Qualitätskriterien für die Produktion entsprechen.

Lambda-Konfiguration für LLM Judge

Die Verwendung eines LLM als Richter ist eine Erweiterung der Verwendung von Lambda-Funktionen für Reinforcement Learning with Verifiable Rewards (RLVR). In der Lambda-Funktion rufen Sie eines der in Amazon Bedrock gehosteten Modelle auf.

## Wichtige Konfigurationsanforderungen:

| Konfiguration             | Anforderung                   | Details                                                                                                                                                                     |
|---------------------------|-------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Amazon Bedrock-Durchsatz  | Ausreichende Quote            | Stellen Sie sicher, dass Ihr Durchsatzkontingent für das verwendete Amazon Bedrock-Modell für Ihren Trainingsaufwand ausreicht                                              |
| Lambda-Zeitüberschreitung | Verlängertes Timeout          | Konfigurieren Sie Ihr Lambda-Funktions-Timeout auf maximal 15 Minuten. Die StandardEinstellung ist 3 Sekunden, was für Amazon Bedrock-Modellantworten nicht ausreichend ist |
| Lambda-Gleichzeitigkeit   | Höhere Parallelität           | Das Lambda wird während des Trainings parallel aufgerufen. Erhöhen Sie die Parallelität, um den verfügbaren Durchsatz zu maximieren                                         |
| Konfiguration des Rezepts | Lambda-Einstellungen anpassen | Das Parallelitätslimit muss in Ihrem Rezept konfiguriert sein                                                                                                               |

## Jobs erstellen und ausführen

### Einen Ausbildungsjob beginnen

Verwenden Sie die Vorlage für ein SageMaker Trainingsjob-Notizbuch: <https://docs.aws.amazon.com/sagemaker/latest/dg/nova-fine-tuning-training-job.html#nova-model-training-jobs-notebook>

## Anforderungen an die Instanz

Der Container unterstützt Full-Rank sowohl LoRa-Schulungen als auch:

- LoRa-Schulung — 2/4/6/8 × p5.48xlarge- oder p5en.48xlarge-Instances
- Full-Rank Schulung 2/4 — 6/8 / × p5.48xlarge-Instanzen (erforderlich)

## Überwachung der Schulung

Die Trainingsprotokolle enthalten bei jedem Schritt umfassende Kennzahlen. Kategorien der wichtigsten Kennzahlen:

## Kennzahlen belohnen

- `critic/rewards/mean,critic/rewards/max, critic/rewards/min` — Verteilung der Prämien
- `val-score/rewards/mean@1` — Prämien für die Validierung

## Verhalten modellieren

- `actor/entropy` — Politische Variation (höher = eher explorativ)

## Gesundheit trainieren

- `actor/pg_loss` — Politischer Gradientenverlust
- `actor/pg_clipfrac` — Häufigkeit abgeschnittener Aktualisierungen
- `actor/grad_norm` — Größe des Gradienten

## Eigenschaften der Reaktion

- `prompt_length/mean,prompt_length/max, prompt_length/min` — Token-Statistiken eingeben
- `response_length/mean,response_length/max, response_length/min` — Token-Statistiken ausgeben
- `response/aborted_ratio` — Unvollständige Generierungsrate (0 = alles abgeschlossen)

## Leistung

- `perf/throughput` — Durchsatz des Trainings
- `perf/time_per_step` — Zeit pro Trainingsschritt
- `timing_per_token_ms/*` — Per-token Bearbeitungszeiten

## Nutzung von Ressourcen

- `perf/max_memory_allocated_gb, perf/max_memory_reserved_gb` — GPU-Speicher
- `perf/cpu_memory_used_gb` — CPU-Speicher

## Verwendung fein abgestimmter Modelle

Nach Abschluss des Trainings wird der endgültige Modellprüfpunkt an Ihrem angegebenen Ausgabeort gespeichert. Der Checkpoint-Pfad ist verfügbar in:

- Trainingsprotokolle
- `manifest.json` Datei im Amazon S3 S3-Ausgabespeicherort (definiert durch `output_s3_uri` in Ihrem Notizbuch)

## Einschränkungen und bewährte Methoden

### Einschränkungen

- Lambda-Timeout — Belohnungsfunktionen müssen innerhalb von 15 Minuten abgeschlossen sein (verhindert außer Kontrolle geratene Prozesse und verwaltet die Kosten)
- Single-turn nur — Multi-turn Konversationen werden nicht unterstützt
- Datenanforderungen — Benötigt ausreichend Vielfalt; hat Probleme mit spärlichen Belohnungen (< 5% positive Beispiele)
- Rechenkosten — Teurer als überwachte Feinabstimmung
- Keine multimodalen Daten — Es wird nur der Textdatentyp unterstützt

## Best Practices

### Fangen Sie klein an

- Beginnen Sie mit 100-200 Beispielen
- Überprüfen Sie die Richtigkeit der Belohnungsfunktion
- Skalieren Sie schrittweise auf der Grundlage der Ergebnisse

### Pre-training Auswertung

- Testen Sie die Leistung des Basismodells vor der RFT
- Liegen die Prämien durchweg bei 0%, verwenden Sie zunächst SFT, um die grundlegenden Funktionen festzulegen
- Liegen die Prämien bei > 95%, ist RFT möglicherweise unnötig

## Überwachen Sie das Training

- Verfolge die durchschnittlichen Punktzahlen und die Verteilung der Prämien
- Achten Sie auf Überanpassung (die Trainingsbelohnungen steigen, während die Validierungsprämien sinken)
- Achten Sie auf besorgniserregende Muster:
  - Die Belohnungen bewegen sich unter 0,15
  - Zunehmende Varianz der Belohnungen im Laufe der Zeit
  - Sinkende Validierungsleistung

## Optimieren Sie die Belohnungsfunktionen

- Innerhalb von Sekunden (nicht Minuten) ausführen
- Minimiere externe API-Aufrufe
- Verwenden Sie effiziente Algorithmen
- Implementieren Sie die richtige Fehlerbehandlung
- Nutzen Sie die parallel Skalierung von Lambda

## Iterationsstrategie

Wenn sich die Belohnungen nicht verbessern:

- Passen Sie das Design der Belohnungsfunktion an
- Erhöhen Sie die Vielfalt der Datensätze
- Fügen Sie weitere repräsentative Beispiele hinzu
- Stellen Sie sicher, dass die Belohnungssignale klar und konsistent sind

## Adaptives Lernen im Lehrplan

Adaptives Lernen im Lehrplan ist eine optionale Funktion, die dynamisch auswählt, welche Schulungsaufforderungen dem Modell während der RFT präsentiert werden sollen. Anstatt bei allen Aufforderungen einheitlich zu trainieren, verwendet der Trainer das Modell selbst, um den Schwierigkeitsgrad der Eingabeaufforderung vorherzusagen, und wählt die Eingabeaufforderungen im produktiven Schwierigkeitsbereich aus, in dem das Modell manchmal erfolgreich ist und manchmal fehlschlägt. Auf diese Weise wird die Varianz der Ergebnisse innerhalb der einzelnen GRPO-Rollout-

Gruppen maximiert, was zu einem höheren Vorteilssignal, einer schnelleren Konvergenz und einer verbesserten Stabilität des RL-Trainings führt, da es weniger rauschende Gradientenaktualisierungen aufgrund von zu einfachen oder zu schwierigen Eingabeaufforderungen gibt.

### Wie funktioniert ein adaptiver Lehrplan

Wenn der adaptive Lehrplan aktiviert ist, fügt die Trainingsschleife vor jedem Rollout-Schritt eine Prognose- und Auswahlphase hinzu:

1. **Prognose** — Das Modell prognostiziert die Erfolgsquote (oder Prämienverteilung) für jede Kandidatenaufforderung mithilfe eines Fee-Shot-Prognoseformats. Drei Beispiele aus dem vorherigen Trainingsschritt (ein einfacher, ein mittlerer, ein schwieriger) liefern den Kontext zur Kalibrierung.
2. **Auswahl** — Eingabeaufforderungen werden danach geordnet, wie nahe ihr vorhergesagter Schwierigkeitsgrad am Auswahlziel liegt (Standard: Erfolgsquote von 50%). Die besten Eingabeaufforderungen werden für den Rollout genehmigt; der Rest wird verworfen, ohne dass der Rollout Rechenleistung verbraucht.
3. **Schulung** — Die GRPO-Standardschulung wird anhand der ausgewählten Eingabeaufforderungen fortgesetzt.
4. **Feedback** — Die tatsächlichen Erfolgsquoten beim Rollout werden mit den Prognosen verglichen. Das Auswahlziel wird automatisch kalibriert, um systematische Prognosefehler zu korrigieren. Ein REINFORCE-Gradient trainiert den Prädiktor, um future Vorhersagen zu verbessern.

### Wann sollte ein adaptiver Lehrplan verwendet werden

Ein adaptiver Lehrplan ist in den folgenden Szenarien am effektivsten:

- Sie möchten die Stabilität des RL-Trainings verbessern, indem Sie sicherstellen, dass jeder Trainingsstapel Aufforderungen mit einer aussagekräftigen Varianz der Belohnungen enthält. Dadurch werden störende Gradientenaktualisierungen vermieden, die das Lernen destabilisieren können.
- Sie haben bestätigt, dass die grundlegende RFT-Methode Ihre Zielkennzahl verbessert.
- Sie möchten die Konvergenz beschleunigen, indem Sie die Trainingsberechnungen auf die produktivsten Eingabeaufforderungen konzentrieren.
- Ihr Datensatz ist umfangreich (über 5.000 Eingabeaufforderungen) und enthält viele Eingabeaufforderungen, die außerhalb des produktiven Schwierigkeitsgrads liegen und sonst Rechenleistung verschwenden würden.



## Konfiguration eines adaptiven Lehrplans

Fügen Sie den `adaptive_curriculum` Block unten `trainer` in Ihr Rezept ein, um das Lernen mit adaptivem Lehrplan zu ermöglichen:

```
training_config:
 trainer:
 adaptive_curriculum:
 enable: true # Enable adaptive curriculum prompt
 selection.
 selection_pool_multiplier: 8 # Score 8 x global_batch_size
 candidates, keep best global_batch_size.
 prediction_mode: pass_rate # "pass_rate" for discrete rewards;
 "spread" for continuous rewards.
 exemplar_history_steps: 1 # Previous training steps kept in the
 rolling exemplar history buffer.
 reinforce_coef: 0.01 # Scale factor for the REINFORCE loss
 that trains the predictor (0 disables).
 predictor_prompt_column: predictor_prompt # Dataset field with clean problem
 text used by the predictor.
 selection_lookahead_steps: 4 # Future training batches pre-approved
 per curriculum screening pass.
```

In der folgenden Tabelle werden die einzelnen Parameter des adaptiven Lehrplans beschrieben:

| Parameter                              | Typ             | Standard           | Description                                                                                                                                                                                                                                                                                                |
|----------------------------------------|-----------------|--------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <code>enable</code>                    | Boolesch        | <code>false</code> | Ob die Eingabeaufforderung für den adaptiven Studienplan aktiviert werden soll.                                                                                                                                                                                                                            |
| <code>selection_pool_multiplier</code> | Ganzzahl (1–32) | 8                  | Steuert, wie viele Kandidatenaufforderungen im Verhältnis zur Größe des Trainingsstapels bewertet werden. Ein Wert von 8 bedeutet, dass $8 \times \text{global\_batch\_size}$ Eingabeaufforderungen bewertet und die besten ausgewählt <code>global_batch_size</code> werden. Höhere Werte sorgen für eine |

| Parameter                           | Typ                   | Standard               | Description                                                                                                                                                                                                                                                                                                                                                                                                                                             |
|-------------------------------------|-----------------------|------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
|                                     |                       |                        | bessere Auswahlqualität, kosten jedoch mehr Inferenzberechnungen.                                                                                                                                                                                                                                                                                                                                                                                       |
| <code>prediction_mode</code>        | Zeichenfolge          | <code>pass_rate</code> | Prognosemodus für eine schnelle Schätzung des Schwierigkeitsgrades. Wird <code>pass_rate</code> für diskrete Belohnungsaufgaben (z. B. Korrektheitsprüfung) verwendet, bei denen der Prädiktor die Wahrscheinlichkeit einer richtigen Antwort schätzt. Wird <code>spread</code> für Aufgaben mit kontinuierlicher Belohnung verwendet, bei denen der Prädiktor die Verteilung der maximalen und minimalen Belohnung auf die einzelnen Rollouts schätzt. |
| <code>exemplar_history_steps</code> | Ganzzahl ( $\geq 1$ ) | 1                      | Anzahl der vorherigen Trainingsschritte, die im fortlaufenden Verlaufspuffer für die Probenauswahl gespeichert werden sollen. Der Prädiktor verwendet Exemplare aus dieser Historie, um seine wenigen Vorhersagen zu kalibrieren.                                                                                                                                                                                                                       |
| <code>reinforce_coef</code>         | Zahl ( $\geq 0$ )     | 0.01                   | Skalierungsfaktor für den REINFORCE-Verlust, der den Prädiktor für die Erfolgsquote trainiert. Dies ermöglicht ein Lernen in einem geschlossenen Regelkreis, bei dem der Prädiktor seine Genauigkeit im Laufe des Trainings verbessert. Auf 0 setzen, um das Prädiktortraining zu deaktivieren.                                                                                                                                                         |

| Parameter                              | Typ             | Standard                      | Description                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                |
|----------------------------------------|-----------------|-------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <code>predictor_prompt_column</code>   | Zeichenfolge    | <code>predictor_prompt</code> | Feldname im Datensatz, der den fehlerfreien Problemtext enthält, der als Prädiktor-Prompt verwendet wurde. Dabei sollte es sich um eine präzise Version des Problems ohne Systemaufforderungen oder Formatierung handeln, sodass der Prädiktor den Schwierigkeitsgrad schnell einschätzen kann.                                                                                                                                                                                                                                                                                                                                                                                                                                                                            |
| <code>selection_lookahead_steps</code> | Ganzzahl (1—16) | 4                             | Anzahl der future Schulungschargen, die vorab genehmigt werden müssen, in einem einzigen Prüfdurchgang für den Lehrplan pro Schritt. Bei jedem Durchlauf werden die <code>selection_pool_multiplier</code> × <code>global_batch_size</code> Kandidaten pro Schritt bewertet. Höhere <code>selection_lookahead_steps</code> Wiederholungswerte, die mehrfach bestanden werden, bilden eine Warteschlange mit genehmigten Aufforderungen, wodurch der Aufwand pro Schritt für Prädiktoren bei Datensätzen mit kurzen Aufforderungen reduziert wird. Bei Datensätzen mit langem Kontext, bei denen der Prädiktor selbst teuer ist (siehe Abschnitt mit den Empfehlungen), sollten Sie diesen Wert 1 so einstellen, dass der Prädiktor nur einmal pro Schritt ausgeführt wird. |

## Empfehlungen für Datensätze mit langem Kontext

Bei einem adaptiven Curriculum wird ein einfacher Prädiktor für die Erfolgsquote anhand eines Pools von Bewerberanfragen ausgeführt und der produktivste Stapel für die Einführung ausgewählt. Wenn der `max_prompt_length` Wert kurz ist (ein paar Tausend Token oder weniger), wird der Prädiktor in wenigen Sekunden pro Prüfungsdurchgang ausgeführt, und der Aufwand für den Lehrplan ist vernachlässigbar. Wenn die Länge der Eingabeaufforderung zunimmt, nimmt die Inferenzzeit des Prädiktors ungefähr quadratisch zu (die Aufmerksamkeit entspricht der Sequenzlänge  $O(n^2)$ ), sodass das Screening die Schrittzeit bei Datensätzen dominieren kann, bei denen die Eingabeaufforderungen etwa 8.000 Tokens überschreiten.

 Note

Der adaptive Lehrplan wird für `max_prompt_length` bis zu 32.768 Tokens (32.000) unterstützt. Die Aktivierung für Datensätze, die diese Länge überschreiten, wird nicht unterstützt. Deaktivieren Sie den adaptiven Lehrplan oder verkürzen Sie Ihre Eingabeaufforderungen vor dem Training.

Die folgenden Einstellungen sorgen dafür, dass der adaptive Lehrplan auch bei Datensätzen mit langem Kontext nutzbar und kostengünstig ist. Wenden Sie sie zusammen an; sie beziehen sich auf verschiedene Komponenten der Screening-Kosten.

| Typisch <code>max_prompt_length</code> | Empfohlene Einstellungen für den adaptiven Lehrplan                                                                                                                                                                                                                       |
|----------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Bis zu 8.000 Token                     | Standardwerte verwenden: <code>selection_pool_multiplier: 8</code> ,<br><code>selection_lookahead_steps: 4</code> Der Screening-Aufwand ist gering und muss nicht angepasst werden.                                                                                       |
| Über 8.000 und bis zu 16.000 Token     | Set <code>selection_lookahead_steps: 2</code> . Dadurch wird die Anzahl der Prädiktordurchläufe pro Schritt halbiert, während gleichzeitig genügend vorab genehmigte Eingabeaufforderungen in der Warteschlange verbleiben, um zu verhindern, dass der Rollout ausbleibt. |
| Über 16.000 und bis zu 24.000 Tokens   | Behalte <code>selection_lookahead_steps: 2</code> und <code>selection_pool_multiplier</code> senke auf. 4 Der kleinere Pool halbiert                                                                                                                                      |

| Typisch <code>max_prompt_length</code> | Empfohlene Einstellungen für den adaptiven Lehrplan                                                                                                                                                                                                                                                             |
|----------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
|                                        | die Chargengröße des Prädiktors auf Kosten der Auswahlqualität. Zusammen halten sie die Screening-Zeit pro Schritt begrenzt.                                                                                                                                                                                    |
| Über 24.000 und bis zu 32.000 Token    | Verwenden der <code>selection_pool_multiplier: 4</code> mit <code>selection_lookahead_steps: 1</code> . Der Prädiktor wird einmal pro Trainings schritt in einem Pool mit minimaler Größe ausgeführt. Dies ist die aggressivste unterstützte Einstellung. Eine Überschreitung von 32 KB wird nicht unterstützt. |

Beispielkonfiguration, abgestimmt auf einen Datensatz mit langem Kontext (etwa 24.000 bis 32.000 Token-Eingabeaufforderungen):

```
training_config:
 max_length: 32768
 global_batch_size: 32

 trainer:
 adaptive_curriculum:
 enable: true
 selection_pool_multiplier: 4 # Smaller pool keeps predictor prefill
 bounded.
 selection_lookahead_steps: 1 # Predictor runs once per training step.
 prediction_mode: pass_rate
 exemplar_history_steps: 1
 reinforce_coef: 0.01
 predictor_prompt_column: predictor_prompt
```

## Datenaufbereitung für einen adaptiven Lehrplan

Wenn Sie einen adaptiven Lehrplan verwenden, sollten Ihre Trainingsdaten ein `predictor_prompt` Feld (oder den unter angegebenen Feldnamen `predictor_prompt_column`) enthalten, das eine kurze Version des Problemtextes enthält. Dieses Feld wird vom Prädiktor für die Erfolgsquote verwendet, um schnell den Schwierigkeitsgrad des Gesprächs einzuschätzen, ohne den gesamten Konversationskontext verarbeiten zu müssen.

Beispiel für einen JSONL-Eintrag mit Prädiktor-Eingabeaufforderung:

```
{
 "messages": [
 {
 "role": "system",
 "content": "You are a math tutor. Show your work step by step."
 },
 {
 "role": "user",
 "content": "A train travels 120 miles in 2 hours. If it then increases speed by 50%, how far will it travel in the next 3 hours?"
 }
],
 "reference_answer": "270 miles",
 "predictor_prompt": "A train travels 120 miles in 2 hours. Speed increases 50%. Distance in next 3 hours?"
}
```

Wenn das `predictor_prompt` Feld nicht vorhanden ist, verwendet das System wieder die vollständige Eingabeaufforderung aus dem Feld `messages`

### Vollständiges Rezeptbeispiel mit adaptivem Lehrplan

Das folgende Beispiel zeigt ein vollständiges LoRa-RFT-Rezept mit aktiviertem adaptivem Lehrplan:

```
run:
 name: "my-rft-adaptive-curriculum"
 model_type: amazon.nova-2-lite-v1:0:256k
 model_name_or_path: nova-lite-2/prod
 data_s3_path: s3://<bucket>/<data-file>
 replicas: 4
 generation_replicas: 2
 reward_lambda_arn: arn:aws:lambda:<region>:<account-id>:function:<function-name>

training_config:
 max_length: 8192
 global_batch_size: 32
 reasoning_effort: null # Non-reasoning mode.

data:
 shuffle: true

rollout:
 rollout_strategy:
```

```

 type: off_policy_async
 age_tolerance: 2
 advantage_strategy:
 number_generation: 16 # Higher n for better advantage
estimates.
 generator:
 max_new_tokens: 6000
 temperature: 1.0
 rewards:
 preset_reward_function: exact_match # Or null for custom Lambda reward.
 api_endpoint:
 lambda_arn: ${oc.select:run.reward_lambda_arn} # Reuse the top-level
run.reward_lambda_arn so the two stay in sync.
 lambda_concurrency_limit: 12
 lambda_batch_size: 128

trainer:
 max_steps: 500
 save_steps: 50
 test_steps: 25
 refit_freq: 4
 clip_ratio_high: 0.2
 ent_coeff: 0.0
 kl_loss_coef: 0.0

optim_config:
 lr: 1e-6
 weight_decay: 0.0

peft:
 peft_scheme: "lora"
 lora_tuning:
 alpha: 64
 lora_plus_lr_ratio: 64.0

adaptive_curriculum:
 enable: true
 selection_pool_multiplier: 8
 prediction_mode: pass_rate
 exemplar_history_steps: 1
 reinforce_coef: 0.01
 predictor_prompt_column: predictor_prompt

```

## Überwachung des adaptiven Lehrplans

Wenn der adaptive Lehrplan aktiviert ist, werden bei jedem Trainingsschritt zusätzliche Messwerte protokolliert:

- **Prognostizierte und tatsächliche Erfolgsquote** — Die durchschnittliche prognostizierte Erfolgsquote für ausgewählte Eingabeaufforderungen im Vergleich zur tatsächlichen Erfolgsquote, die nach der Einführung beobachtet wurde. Eine große Lücke deutet darauf hin, dass der Prädiktor mehr Kalibrierungszeit benötigt.
- **Auswahlziel** — Das aktuelle automatisch kalibrierte Auswahlziel. Es beginnt bei 0,5 und wird auf der Grundlage der Vorhersagegenauigkeit angepasst.
- **Anzahl der Mastery-Filter** — Anzahl der ausgeschlossenen Eingabeaufforderungen, da das Modell sie konsistent gemeistert hat.

### Note

Die ersten 1—2 Trainingsschritte werden ohne adaptive Auswahl ausgeführt (der Prädiktor benötigt mindestens einen historischen Schritt, um Exemplare zu erstellen). Die vollständige adaptive Auswahl beginnt bei Schritt 3.

## Erweiterte Funktionen: Nova Forge

Für Benutzer, die erweiterte Funktionen benötigen, die über die standardmäßigen RFT-Beschränkungen hinausgehen, ist Nova Forge als kostenpflichtiger Abonnementdienst erhältlich und bietet:

- Multi-turn Unterstützung bei Konversationen
- Belohnen Sie Funktionen mit einer Ausführungszeit von > 15 Minuten
- Zusätzliche Algorithmen und Optimierungsoptionen
- Änderungen an benutzerdefinierten Trainingsrezepten
- State-of-the-art KI-Techniken

Nova Forge läuft auf SageMaker HyperPod und wurde entwickelt, um Unternehmenskunden dabei zu unterstützen, ihre eigenen Grenzmodelle zu entwickeln.



## Nützliche Befehle und Tipps

Es steht eine Sammlung von [Observability-Skripten](#) zur Verfügung, mit deren Hilfe der Status und Fortschritt von Schulungsaufgaben überwacht werden kann.

Verfügbare Skripte sind:

- Aktivierung von E-Mail-Benachrichtigungen für Statusaktualisierungen von Schulungsaufträgen
- Abrufen von Schätzungen der Schulungszeit auf der Grundlage von Jobkonfigurationen
- Einholung von Näherungswerten darüber, wie lange die Schulung für laufende Tätigkeiten voraussichtlich dauern wird

## Installation

### Note

Stellen Sie sicher, dass Sie Ihre AWS Anmeldeinformationen aktualisieren, bevor Sie eines der folgenden Skripts verwenden.

```
pip install boto3
git clone https://github.com/aws-samples/amazon-nova-samples.git
cd amazon-nova-samples/customization/SageMakerUilts/SageMakerJobsMonitoring/
```

## Grundlegende Verwendung

```
Enabling email notifications for training job status updates
python enable_sagemaker_job_notifs.py --email test@amazon.com test2@gmail.com --region
us-east-1 --platform SMTJ
```

Creating resources.....

Please check your email for a subscription confirmation email, and click 'Confirm subscription' to start receiving job status email notifications!

You'll receive the confirmation email within a few minutes.

```
Obtaining training time estimates based on job configurations
python get_training_time_estimate.py
```

```
Obtaining approximations for how long training is expected to take for in-progress jobs
python get-training-job-progress.py --region us-east-1 --job-name my-training-job --num-dataset-samples 1000
```

Weitere Informationen und [Beispiele finden Sie in der README-Datei zu den Überwachungsskripten von Amazon Nova Samples](#).



## Überwachung des Fortschritts über mehrere Iterationen hinweg

Sie können Metriken über MLflow verfolgen.

### Nova-Anpassung — MLFlow-Setup für SageMaker HyperPod

Damit Ihre SageMaker HyperPod Umgebung Metriken an MLflow ausgeben kann, müssen Sie einige zusätzliche Einstellungen vornehmen.

1. Öffnen Sie Amazon SageMaker AI
2. Wählen Sie SageMaker Studio
  - a. Wenn bereits ein Profil erstellt wurde, wählen Sie „Studio öffnen“.
  - b. Wenn kein Profil erstellt wurde, wählen Sie „Eine SageMaker Domain erstellen“, um eines einzurichten
3. Wählen Sie MLflow. Wenn keine MLflow App erstellt wurde, wählen Sie „MLflow App erstellen“
4. Klicken Sie in der ML Flow App auf die copy/paste Schaltfläche oder den Menüpunkt „Details anzeigen“, um den ARN abzurufen. Sie benötigen dies, wenn Sie Ihren Ausbildungsjob einreichen.



5. Fügen Sie der HyperPod Cluster-Ausführungsrolle die folgende Richtlinie hinzu. Dadurch kann der HyperPod Cluster die MLflow-API aufrufen, um Metriken zu veröffentlichen.

```
{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Effect": "Allow",
 "Action": "sagemaker-mlflow:*",
 "Resource": [
 "arn:aws:sagemaker:us-east-1:372836560492:mlflow-app/*"
]
 },
 {
 "Effect": "Allow",
 "Action": [
 "sagemaker:ListMlflowTrackingServers",
 "sagemaker:CallMlflowAppApi"
],
 "Resource": "*"
 }
]
}
```

## Einen Job über die CLI einreichen

Geben Sie 4 neue Override-Parameter an, entweder in der Befehlszeile oder im Rezept yaml.

1. `mlflow_tracking_uri`: Der ARN der MLflow App
2. `mlflow_experiment_name`: Der Name für diesen Durchlauf des Experiments
3. `mlflow_experiment_name`: Der Name des Experiments, in dem die Metriken in MLflow gespeichert werden
4. `mlflow_run_name`: Der Name für dieses Experiment

## Befehlszeile

```
--override-parameters '{"recipes.run.mlflow_tracking_uri": "arn:aws:sagemaker:us-east-1:925548216816:mlflow-app/app-B6X0UNCHQM4W", "recipes.run.mlflow_experiment_name": "myuser-sft-lora-exp1", "recipes.run.mlflow_run_name": "myuser-sft-lora-exp1-202512181940"}'
```


yaml:

```
Run config
run:
 mlflow_tracking_uri: "arn:aws:sagemaker:us-east-1:925548216816:mlflow-app/app-
B6X0UNCHQM4W"
 mlflow_experiment_name: "myuser-sft-lora-exp1"
 mlflow_run_name: "myuser-sft-lora-exp1-202512181940"
```

Einen Job über die SageMaker Studio-Benutzeroberfläche einreichen

Die MLflow-Integration ist bereits in die SageMaker Studio-Benutzeroberfläche integriert. Wenn Sie einen Schulungsjob einreichen, geben Sie einfach an, welche MLflow App-Instanz verwendet werden soll.

1. Navigieren Sie in SageMaker Studio zu Modelle > Nova 2.0 Lite > Anpassen > Mit UI anpassen.
2. Erweitern Sie den Abschnitt Erweiterte Konfiguration
3. Wählen Sie die MLflow App aus, an die Sie die Trainingsmetriken senden möchten. Sie können hier auch Ihren Experimentnamen festlegen und das Experiment ausführen.



MLflow

**MLflow Resource**  
MLflow resource selected for experiment tracking.

DefaultMLFlowApp

**Experiment name**  
Default name applied. Enter a new name if desired.

myuser-sft-lora-exp1

**Experiment run**  
The run name is autogenerated by default. Specify a new name if desired.

myuser-sft-lora-exp1-1766499113356

Einreichen eines Jobs über AWS CLI

Wenn Sie die verwenden AWS CLI, müssen Sie eine MLFlow-App erstellen und sie als Eingabe für die API-Anfrage für den Schulungsjob übergeben.

```
mlflow_app_name="<enter your MLflow app name>"
role_arn="<enter your role ARN>"
bucket_name="<enter your bucket name>"
region="<enter your region>"

mlflow_app_arn=$(aws sagemaker create-mlflow-app \
 --name $mlflow_app_name \
 --artifact-store-uri "s3://$bucket_name" \
 --role-arn $role_arn \
 --region $region)
```

## Erstellen Sie eine MLFlow-App

Verwenden der Studio-Benutzeroberfläche: Wenn Sie einen Trainingsjob über die Studio-Benutzeroberfläche erstellen, wird automatisch eine standardmäßige MLflow-Anwendung erstellt und standardmäßig unter Erweiterte Optionen ausgewählt.

Verwenden von CLI: Wenn Sie die CLI verwenden, müssen Sie eine MLFlow-App erstellen und sie als Eingabe an die API-Anfrage für den Trainingsjob übergeben.

```
mlflow_app_name="<enter your MLflow app name>"
role_arn="<enter your role ARN>"
bucket_name="<enter your bucket name>"
region="<enter your region>"

mlflow_app_arn=$(aws sagemaker create-mlflow-app \
 --name $mlflow_app_name \
 --artifact-store-uri "s3://$bucket_name" \
 --role-arn $role_arn \
 --region $region)
```

## Greifen Sie auf die MLFlow-App zu

Verwenden von CLI: Erstellen Sie eine vorsignierte URL für den Zugriff auf die Benutzeroberfläche der MLflow-App:

```
aws sagemaker create-presigned-mlflow-app-url \
 --arn $mlflow_app_arn \
 --region $region \
 --output text
```

Verwenden der Studio-Benutzeroberfläche: Die Studio-Benutzeroberfläche zeigt wichtige Kennzahlen an, die in MLflow gespeichert sind, und bietet einen Link zur Benutzeroberfläche der MLflow-App.

## Wichtige Kennzahlen, die es zu verfolgen gilt

Überwachen Sie diese Kennzahlen in allen Iterationen, um die Verbesserung zu bewerten und den Arbeitsfortschritt zu verfolgen:

### Für SFT

- Verlustkurven beim Training
- Anzahl der verbrauchten Proben und Zeit für die Probenverarbeitung
- Leistungsgenauigkeit bei ausgereckten Testgeräten
- Formatkonformität (z. B. gültige JSON-Ausgaberate)
- Unklarheit über domänenspezifische Bewertungsdaten

### Für RFT

- Durchschnittliche Belohnungspunktzahlen im Vergleich zum Training
- Verteilung der Prämien (Prozentsatz der Antworten mit hoher Prämie)
- Trends bei der Validierung von Prämien (achten Sie auf zu hohe Anforderungen)
- Task-specific Erfolgsquoten (z. B. Erfolgsquote bei der Codeausführung, Genauigkeit mathematischer Probleme)

### General

- Benchmark-Leistungsdeltas zwischen Iterationen
- Bewertungsergebnisse am Menschen anhand repräsentativer Stichproben
- Produktionskennzahlen (bei iterativer Bereitstellung)

## Feststellen, wann gestoppt werden soll

Beenden Sie die Iteration, wenn:

- Leistungsplateaus: Zusätzliche Schulungen verbessern die Zielkennzahlen nicht mehr nennenswert

- Technikwechsel hilft: Wenn bei einer Technik ein Plateau auftritt, versuchen Sie, zu wechseln (z. B. SFT → RFT → SFT), um die Leistungsobergrenzen zu durchbrechen
- Erreichte Zielkennzahlen: Ihre Erfolgskriterien sind erfüllt
- Regression erkannt: Neue Iterationen verschlechtern die Leistung (siehe Rollback-Verfahren unten)

Ausführliche Bewertungsverfahren finden Sie im Abschnitt [Bewertung](#).

## Evaluieren Sie Ihr SageMaker AI-trained Modell

Der Zweck des Bewertungsprozesses besteht darin, die Leistung des trainierten Modells anhand von Benchmarks oder benutzerdefinierten Datensätzen zu bewerten. Der Bewertungsprozess umfasst in der Regel Schritte zur Erstellung eines Bewertungsrezepts, das auf das trainierte Modell verweist, zur Festlegung von Bewertungsdatensätzen und -metriken, zur Einreichung eines separaten Jobs für die Bewertung und zur Bewertung anhand von Standardbenchmarks oder benutzerdefinierten Daten. Der Bewertungsprozess gibt Leistungsmetriken aus, die in Ihrem Amazon-S3-Bucket gespeichert sind.

### Note

Sie können Ihre Modelle auch mit [Inspect AI](#) bewerten, einem Open-Source-Evaluierungsframework, das standardisierte Benchmarks und benutzerdefinierte Bewertungsaufgaben unterstützt.

### Note

Der in diesem Thema beschriebene Bewertungsprozess ist ein Offline-Prozess. Das Modell wird anhand festgelegter Benchmarks mit vordefinierten Antworten getestet, statt in Echtzeit oder anhand von Live-Benutzerinteraktionen bewertet zu werden. Für die Echtzeitbewertung können Sie das Modell testen, nachdem es auf Amazon Bedrock bereitgestellt wurde, indem Sie die Laufzeit-APIs von [Amazon Bedrock](#) aufrufen.

## Themen

- [Voraussetzungen](#)
- [Verfügbare Benchmark-Aufgaben](#)
- [Bewertung spezifischer Konfigurationen](#)

- [Ausführen von Bewertungs-Trainingsjobs](#)
- [Auswertung und Analyse der Bewertungsergebnisse](#)
- [Bewährte Methoden zur Bewertung und Problembehebung](#)
- [Verfügbare Unteraufgaben](#)
- [Bewertung des Argumentationsmodells](#)
- [RFT-Evaluierung](#)
- [Implementierung von Belohnungsfunktionen](#)

## Voraussetzungen

Bevor Sie einen Bewertungs-Trainingsjob beginnen, sollten Sie Folgendes beachten.

- Ein SageMaker AI-trained Amazon Nova-Modell, dessen Leistung Sie bewerten möchten.
- Amazon-Nova-Basisrezept zur Bewertung Weitere Informationen finden Sie unter [???](#).

## Verfügbare Benchmark-Aufgaben

Es ist ein Beispielcodepaket verfügbar, das zeigt, wie Benchmark-Metriken mithilfe der SageMaker KI-Modellbewertungsfunktion für Amazon Nova berechnet werden. Informationen zum Zugriff auf die Codepakete finden Sie unter [sample- Nova-ligheval-custom-task](#).

Hier finden Sie eine Liste unterstützter, verfügbarer Industriestandard-Benchmarks. Sie können die folgenden Benchmarks für den Parameter `eval_task` angeben.

### Verfügbare Benchmarks für die Modellbewertung

| Benchmark | Modalität | Description                                                 | Kennzahlen  | Strategie | Unteraufgabe verfügbar |
|-----------|-----------|-------------------------------------------------------------|-------------|-----------|------------------------|
| mmlu      | Text      | Multi-task Sprachverständnis — Testet Wissen in 57 Fächern. | Richtigkeit | zs_cot    | Ja                     |



| Benchmark | Modalität | Description                                                                                                                                                                              | Kennzahlen  | Strategie | Unteraufgabe verfügbar |
|-----------|-----------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------|-----------|------------------------|
| mmlu_pro  | Text      | MMLU – professioneller Bereich – konzentriert sich auf Fachbereiche wie Recht, Medizin, Rechnungswesen und Ingenieurwesen.                                                               | Richtigkeit | zs_cot    | Nein                   |
| bbh       | Text      | Fortschrittliche Argumentationsaufgaben – eine Sammlung herausfordernder Probleme, die kognitive Fähigkeiten und Fähigkeiten zur Problemlösung auf höherem Niveau auf die Probe stellen. | Richtigkeit | fs_cot    | Ja                     |

| Benchmark | Modalität | Description                                                                                                                                             | Kennzahlen  | Strategie | Unteraufgabe verfügbar |
|-----------|-----------|---------------------------------------------------------------------------------------------------------------------------------------------------------|-------------|-----------|------------------------|
| gpqa      | Text      | Beantwortung allgemeiner Fragen zur Physik – beurteilt das Verständnis physikalischer Konzepte und die damit verbundenen Fähigkeiten zur Problemlösung. | Richtigkeit | zs_cot    | Nein                   |

| Benchmark     | Modalität | Description                                                                                                                                             | Kennzahlen  | Strategie | Unteraufgabe verfügbar |
|---------------|-----------|---------------------------------------------------------------------------------------------------------------------------------------------------------|-------------|-----------|------------------------|
| math          | Text      | Mathematische Problemlösung – bewertet mathematische Überlegungen in verschiedenen Themenbereichen wie Algebra, Infinitesimalrechnung und Textaufgaben. | exact_match | zs_cot    | Ja                     |
| strong_reject | Text      | Quality-Control Aufgabe — Testet die Fähigkeit des Modells, unangemessene, schädliche oder falsche Inhalte zu erkennen und abzulehnen.                  | deflection  | zs        | Ja                     |

| Benchmark | Modalität | Description                                                                                                                                        | Kennzahlen  | Strategie | Unteraufgabe verfügbar |
|-----------|-----------|----------------------------------------------------------------------------------------------------------------------------------------------------|-------------|-----------|------------------------|
| ifeval    | Text      | Instruction-Following<br>Bewertung<br>— Prüft, wie genau ein Modell bestimmte Anweisungen befolgt und Aufgaben gemäß den Spezifikationen ausführt. | Richtigkeit | zs        | Nein                   |

| Benchmark | Modalität          | Description                                                                                                                                                                                                                                                                                                                                                                           | Kennzahlen | Strategie | Unteraufgabe verfügbar |
|-----------|--------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------|-----------|------------------------|
| gen_qa    | Multi-Modal (Bild) | <p>Auswertung benutzerdefinierter Datensätze — Ermöglicht es Ihnen, Ihren eigenen Datensatz für das Benchmarking bereitzustellen und die Modellergebnisse mit Referenzantworten anhand von Metriken wie ROUGE und BLEU zu vergleichen.</p> <p>gen_qaunterstützt Bildinferenz für Modelle, die auf Amazon Nova Lite oder Amazon Nova Pro basieren. Unterstützt auch Bring-Your-Own</p> | all        | gen_qa    | Nein                   |

| Benchmark | Modalität   | Description                                                                                                                                                     | Kennzahlen  | Strategie | Unteraufgabe verfügbar |
|-----------|-------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------|-----------|------------------------|
|           |             | Metrics<br>Lambda.<br>(Verwenden Sie für die RFT-Evaluierung bitte das RFT-Eval-Rezept)                                                                         |             |           |                        |
| mmmu      | Multi-Modal | Massive Multidiscipline Multimodal Understanding (MMMU) — College-level Benchmark, bestehend aus Multiple-Choice-Fragen und offenen Fragen aus 30 Disziplinen.) | Richtigkeit | zs_cot    | Ja                     |

| Benchmark | Modalität | Description                                                                                                                                                                                                                                                      | Kennzahlen | Strategie | Unteraufgabe verfügbar |
|-----------|-----------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------|-----------|------------------------|
| llm_judge | Text      | LLM-as-a-Judge<br>Präferenzvergleich —<br>Verwendet ein Nova Judge-Modell, um die Präferenz zwischen Antwortpaaren (B im Vergleich zu A) für Ihre Eingabeaufforderungen zu ermitteln und die Wahrscheinlichkeit zu berechnen, dass B gegenüber A bevorzugt wird. | all        | judge     | Nein                   |

| Benchmark    | Modalität          | Description                                                                                                                                                         | Kennzahlen | Strategie | Unteraufgabe verfügbar |
|--------------|--------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------|-----------|------------------------|
| mm_llm_judge | Multi-Modal (Bild) | Dieser neue Benchmark verhält sich genauso wie der obige textbasierte llm_judge Benchmark. Der einzige Unterschied besteht darin, dass er Bildinferenz unterstützt. | all        | judge     | Nein                   |



| Benchmark        | Modalität | Description                                                                                                                                                                                                                                                                                                                                                           | Kennzahlen | Strategie | Unteraufgabe verfügbar |
|------------------|-----------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------|-----------|------------------------|
| rubric_llm_judge | Text      | <p>Rubric Judge ist ein erweitertes LLM-as-a-judge Evaluierungsmodell, das auf Nova 2.0 Lite basiert. Im Gegensatz zum <a href="#">ursprünglichen Richtermodell</a>, das nur Präferenzurteile vorsieht, generiert Rubric Judge dynamisch benutzerdefinierte Bewertungskriterien, die auf jede Aufforderung zugeschnitten sind, und weist detaillierte Bewertungen</p> | all        | judge     | Nein                   |

| Benchmark           | Modalität | Description                                                                                                                                               | Kennzahlen  | Strategie | Unteraufgabe verfügbar |
|---------------------|-----------|-----------------------------------------------------------------------------------------------------------------------------------------------------------|-------------|-----------|------------------------|
|                     |           | für mehrere Dimensionen zu.                                                                                                                               |             |           |                        |
| aime_2024           | Text      | AIME 2024 — Prüfungsaufgaben auf Einladung der American Invitational Mathematics zur Prüfung von fortgeschrittenem mathematischen Denken und Problemlösen | exact_match | zs_cot    | Nein                   |
| Calendar_Scheduling | Text      | Natural Plan — Kalender Scheduling — Aufgabe zum Testen von Planungsfunktionen für die Planung von Besprechungen für mehrere Tage und Personen            | exact_match | fs        | Nein                   |

| Benchmark | Modalität | Description                                                                                                   | Kennzahlen | Strategie | Unteraufgabe verfügbar |
|-----------|-----------|---------------------------------------------------------------------------------------------------------------|------------|-----------|------------------------|
| humaneval | Text      | HumanEval<br>- Ein Benchmark-Datensatz zur Bewertung der Fähigkeiten zur Codegenerierung großer Sprachmodelle | pass@1     | zs        | Nein                   |

## Bewertung spezifischer Konfigurationen

Im Folgenden finden Sie eine Aufschlüsselung der wichtigsten Komponenten des Rezepts sowie Anleitungen dazu, wie Sie sie für Ihre Anwendungsfälle modifizieren können.

### Verstehen und Ändern Ihrer Rezepte

#### Allgemeine Laufkonfiguration

```
run:
 name: eval_job_name
 model_type: amazon.nova-2-lite-v1:0:256k
 model_name_or_path: nova-lite-2/prod # or s3://escrow_bucket/model_location
 replicas: 1
 data_s3_path: ""
 mlflow_tracking_uri: ""
 mlflow_experiment_name : ""
 mlflow_run_name : ""
```

- `name`: ein beschreibender Name für Ihren Bewertungsjob
- `model_type`: gibt die zu verwendende Nova-Modellvariante an. Ändern Sie dieses Feld nicht manuell. Zu den Optionen gehören:
  - `amazon.nova-micro-v1:0:128k`

- `amazon.nova-lite-v1:0:300k`
- `amazon.nova-pro-v1:0:300k`
- `amazon.nova-2-lite-v 1:0:256 k`
- `model_name_or_path`: der Pfad zum Basismodell oder zum S3-Pfad für den Checkpoint nach dem Training. Zu den Optionen gehören:
  - `nova-2 micro/prod`
  - `Nova- lite/prod`
  - `Nova- pro/prod`
  - `Nova-Lite- 2/prod`
- S3-Pfad für den Checkpoint-Pfad nach dem Training (`s3:customer-escrow-111122223333-smjt-<unique_id>/<training_run_name>`)

 Note

## Bewerten eines trainierten Modells

Um ein trainiertes Modell nach einem Nova-SFT-Trainingsjob zu bewerten, gehen Sie nach der Ausführung eines erfolgreichen Trainingsjobs wie folgt vor. Am Ende der Trainingsprotokolle wird die Protokollmeldung „Training ist abgeschlossen“ angezeigt. In Ihrem Ausgabe-Bucket befindet sich auch eine `manifest.json`-Datei, die den Speicherort Ihres Checkpoints enthält. Diese Datei befindet sich in einer `output.tar.gz`-Datei an Ihrem S3-Ausgabeort. Um mit der Bewertung fortzufahren, verwenden Sie diesen Checkpoint, indem Sie ihn in Ihrer Rezeptkonfiguration als Wert für `run.model_name_or_path` festlegen.

- `replica`: Die Anzahl der Recheninstanzen, die für verteilte Inferenzen (Ausführung von Inferenzen über mehrere Knoten) verwendet werden sollen. Stellen Sie einen `replica` Wert auf `> 1` ein, um Inferenz mit mehreren Knoten zu aktivieren, was die Auswertung beschleunigt. Wenn `instance_count` sowohl als auch angegeben `replica` sind, `instance_count` hat dies Vorrang. Beachten Sie, dass mehrere Replikate nur für SageMaker KI-Schulungsjobs gelten, nicht.
- `data_s3_path`: der Amazon-S3-Pfad für den Eingabedatensatz. Dieses Feld ist erforderlich, sollte aber immer leer bleiben.
- `mlflow_tracking_uri`: (Optional) Der Standort des MLflow-Tracking-Servers (nur auf SMHP erforderlich)

- `mlflow_experiment_name`: (Optional) Name des Experiments zur Gruppierung verwandter ML-Läufe
- `mlflow_run_name`: (Optional) Benutzerdefinierter Name für einen bestimmten Trainingslauf innerhalb eines Experiments

## Bewertungskonfiguration

```
evaluation:
 task: mmlu
 strategy: zs_cot
 subtask: abstract_algebra
 metric: accuracy
```

- `task`: gibt den Bewertungs-Benchmark oder die zu verwendende Aufgabe an. Die unterstützte Aufgabe umfasst:
  - `mmlu`
  - `mmlu_pro`
  - `bbh`
  - `gpqa`
  - `math`
  - `strong_reject`
  - `gen_qa`
  - `ifeval`
  - `mmmu`
  - `llm_judge`
  - `mm_llm_judge`
  - `rubric_llm_judge`
  - `aime_2024`
  - `calendar_scheduling`
  - `humaneval`
- `strategy`: definiert den Bewertungsansatz.

- `zs_cot`: Zero-shot Chain of Thought — ein Ansatz zur Entwicklung umfangreicher Sprachmodelle, der zu schrittweisem Denken anregt, ohne dass explizite Beispiele erforderlich sind.
- `fs_cot`: Few-shot Gedankenkette — ein Ansatz, der einige Beispiele für schrittweises Denken bietet, bevor das Modell aufgefordert wird, ein neues Problem zu lösen.
- `zs`: Zero-shot - ein Ansatz zur Lösung eines Problems ohne vorherige Schulungsbeispiele.
- `gen_qa`: spezifische Strategie für die Verwendung eines eigenen Datensatzes
- `judge`: Spezifische Strategie für Nova LLM als Richter und `mm_llm_judge`.
- `subtask`: Optional. Spezifische Komponenten der Bewertungsaufgabe. Eine vollständige Liste der verfügbaren Unteraufgaben finden Sie unter [???](#).
  - Informationen zu den unterstützten Unteraufgaben finden Sie unter „Verfügbare Benchmark-Aufgaben“.
  - Sie sollten dieses Feld entfernen, wenn es keine Benchmark-Unteraufgaben gibt.
- `metric`: die zu verwendende Bewertungsmetrik
  - `accuracy`: Prozentsatz der richtigen Antworten
  - `exact_match`: (für math-Benchmark) gibt die Rate zurück, mit der die eingegebenen vorhergesagten Zeichenketten exakt mit ihren Referenzen übereinstimmen.
  - `deflection`: gibt bei einem Benchmark mit starker Ablehnung die relative Abweichung vom Basismodell und die Differenz der Signifikanzmetriken zurück.
  - `all`:

Gibt für `gen_qa` und das Benchmarking mit eigenem Datensatz die folgenden Metriken zurück:

- `rouge1`: misst die Überlappung von Unigrammen (einzelnen Wörtern) zwischen generiertem Text und Referenztext.
- `rouge2`: misst die Überlappung von Bigrammen (zwei aufeinanderfolgenden Wörtern) zwischen generiertem Text und Referenztext.
- `rougeL`: misst die längste gemeinsame Teilsequenz zwischen Texten und berücksichtigt Lücken beim Abgleich.
- `exact_match`: binärer Wert (0 oder 1), der angibt, ob der generierte Text Zeichen für Zeichen exakt mit dem Referenztext übereinstimmt
- `quasi_exact_match`: ähnlich wie Exact Match, aber weniger strikt, wobei in der Regel Unterschiede zwischen Groß- und Kleinschreibung, Zeichensetzung und Leerzeichen ignoriert

- `f1_score`: harmonisches Mittel zwischen Präzision und Erinnerungswert, das die Wortüberschneidung zwischen vorhergesagten Antworten und Referenzantworten misst
- `f1_score_quasi`: ähnlich wie `f1_score`, jedoch mit weniger striktem Abgleich, bei dem normalisierter Text verglichen und geringfügige Unterschiede ignoriert werden
- `bleu`: misst die Genauigkeit von N-Gramm-Übereinstimmungen zwischen generiertem Text und Referenztext, was häufig bei der Bewertung von Übersetzungen verwendet wird.

Geben Sie für `llm_judge` und `mm_llm_judge`, bringen Sie Ihren eigenen Datensatz-Benchmark mit, folgende Kennzahlen zurück:

- `a_scores`: Anzahl der Siege von `response_A` bei Vorwärts- und Rückwärtsdurchläufen zur Bewertung
- `a_scores_stderr`: Standardfehler von `response_A_scores` bei paarweisen Beurteilungen
- `b_scores`: misst die Anzahl der Siege von `response_B` bei Vorwärts- und Rückwärtsdurchläufen zur Bewertung.
- `b_scores_stderr`: Standardfehler von `response_B_scores` bei paarweisen Beurteilungen
- `ties`: Anzahl der Beurteilungen, bei denen `response_A` und `response_B` als gleichwertig bewertet wurden
- `ties_stderr`: Standardfehler von `ties` bei paarweisen Beurteilungen
- `inference_error`: Anzahl der Beurteilungen, die nicht richtig bewertet werden konnten
- `score`: Gesamtpunktzahl basierend auf Siegen aus Vorwärts- und Rückwärtsdurchläufen für `response_B`
- `score_stderr`: Gesamtpunktzahl basierend auf Siegen aus Vorwärts- und Rückwärtsdurchläufen für `response_B`
- `inference_error_stderr`: Standardfehler der Gesamtpunktzahl bei paarweisen Beurteilungen
- `winrate`: Die Wahrscheinlichkeit, die einer anhand der Wahrscheinlichkeit `response_A` berechneten Bradley-Terry Wahrscheinlichkeit vorgezogen `response_B` wird.
- `lower_rate`: Untergrenze (2,5. Perzentil) der geschätzten Gewinnrate aus dem Bootstrap-Sampling
- `upper_rate`: Obergrenze (97,5. Perzentil) der geschätzten Gewinnrate aus dem Bootstrap-Sampling

## Konfiguration der Inferenz (optional)

```
inference:
 max_new_tokens: 2048
 top_k: -1
 top_p: 1.0
 temperature: 0
 top_logprobs: 10
 reasoning_effort: null # options: low/high to enable reasoning or null to disable
 reasoning
```

- `max_new_tokens`: maximale Anzahl der zu generierenden Token. Muss eine Ganzzahl sein. (Für LLM Judge nicht verfügbar.)
- `top_k`: Anzahl der zu berücksichtigenden Token mit der höchsten Wahrscheinlichkeit. Muss eine Ganzzahl sein.
- `top_p`: kumulativer Wahrscheinlichkeitsschwellenwert für das Token-Sampling. Muss ein Gleitkommawert zwischen 1,0 und 0,0 sein.
- `temperature`: Zufälligkeit bei der Token-Auswahl (höher = eher zufällig). Behalten Sie 0 bei, um ein deterministisches Ergebnis zu erhalten. Typ Float, der Mindestwert ist 0.
- `top_logprobs`: Die Anzahl der wichtigsten Logprobs, die in der Inferenzantwort zurückgegeben werden sollen. Dieser Wert muss eine Ganzzahl zwischen 0 und 20 sein. Logprobs enthalten die betrachteten Ausgabetokens und die Protokollwahrscheinlichkeiten jedes im Nachrichteninhalte zurückgegebenen Ausgabetokens.
- `reasoning_effort`: steuert das Argumentationsverhalten für Modelle, die zum Denken fähig sind. Wird `reasoning_effort` nur gesetzt, wenn (derzeit) ein `model_type` Modell angegeben wird, das zu Argumenten fähig ist. `amazon.nova-2-lite-v1:0:256k` Verfügbare Optionen sind Null (Standardwert, falls nicht festgelegt; deaktiviert Argumentation), Niedrig oder Hoch.

### Ausgabeformat „Log-Wahrscheinlichkeit“

Wenn `top_logprobs` es in Ihren Inferenzeinstellungen konfiguriert ist, enthält die Evaluationsausgabe Protokollwahrscheinlichkeiten auf Tokenebene in den Parquet-Dateien. Jede Token-Position enthält ein Wörterbuch der wichtigsten Token-Kandidaten mit ihren Log-Wahrscheinlichkeiten in der folgenden Struktur:

```
{
 "Ġint": {"logprob_value": -17.8125, "decoded_value": " int"},
 "Ġthe": {"logprob_value": -2.345, "decoded_value": " the"}
}
```



Jeder Token-Eintrag enthält:

- `logprob_value`: Der Log-Wahrscheinlichkeitswert für das Token
- `decoded_value`: Die menschenlesbare dekodierte Zeichenkettendarstellung des Tokens

Das rohe Tokenizer-Token wird als Wörterbuchschlüssel verwendet, um die Einzigartigkeit zu gewährleisten und bietet gleichzeitig eine lesbare Interpretation. `decoded_value`

Beispiele für Bewertungsrezepte

Amazon Nova bietet vier verschiedene Arten von Bewertungsrezepten. [Alle Rezepte sind im SageMaker HyperPod Rezepte-Repository verfügbar. GitHub](#)

Allgemeine Text-Benchmark-Rezepte

Diese Rezepte ermöglichen es Ihnen, die grundlegenden Funktionen von Amazon-Nova-Modellen anhand einer umfassenden Suite von reinen Text-Benchmarks zu bewerten.

Rezeptformat: `xxx_general_text_benchmark_eval.yaml`.

Benchmark-Rezepte mit eigenem Datensatz

Diese Rezepte ermöglichen es Ihnen, Ihren eigenen Datensatz für das Benchmarking zu verwenden und die Modellergebnisse anhand verschiedener Arten von Metriken mit Referenzantworten zu vergleichen.

Rezeptformat: `xxx_bring_your_own_dataset_eval.yaml`.

Anforderungen für die Verwendung des eigenen Datensatzes

Dateiformat:

- Eine einzige `gen_qa.jsonl`-Datei mit Bewertungsbeispielen. Der Dateiname sollte `gen_qa.jsonl` und kein anderer sein.
- Sie müssen Ihren Datensatz an einen S3-Standort hochladen, auf den SageMaker KI-Schulungsjobs zugreifen können.
- Die Datei muss dem erforderlichen Schemaformat für den allgemeinen Q&A-Datensatz entsprechen.

Anforderungen an das Schemaformat — Jede Zeile in der `.jsonl` Datei muss ein JSON-Objekt mit den folgenden Feldern sein.

- Pflichtfelder

`query`: Zeichenfolge, die die Frage oder Anweisung enthält, für die eine Antwort erforderlich ist

`response`: Zeichenfolge, die die erwartete Modellausgabe enthält

- Optionale Felder

`system`: Zeichenfolge, die den System-Prompt enthält, der vor der Verarbeitung der Abfrage das Verhalten, die Rolle oder die Persönlichkeit des KI-Modells festlegt

`images`: Array, das eine Liste von Objekten mit Datenattributen enthält (Base64-kodierte Bildzeichenfolgen).

`metadata`: Zeichenfolge, die Metadaten enthält, die dem Eintrag zu Tagging-Zwecken zugeordnet sind.

## Beispielseintrag

```
{
 "system": "You are an English major with top marks in class who likes to give minimal word responses: ",
 "query": "What is the symbol that ends the sentence as a question",
 "response": "?"
}{
 "system": "You are a pattern analysis specialist who provides succinct answers: ",
 "query": "What is the next number in this series? 1, 2, 4, 8, 16, ?",
 "response": "32"
}{
 "system": "You have great attention to detail and follow instructions accurately: ",
 "query": "Repeat only the last two words of the following: I ate a hamburger today and it was kind of dry",
 "response": "of dry"
}{
 "system": "Image inference: ",
 "query": "What is the number in the image? Please just use one English word to answer.",
 "response": "two",
 "images": [
```

```
{
 "data": "data:image/png;base64,iVBORw0KGgoA ..."
}
```

Um Ihren benutzerdefinierten Datensatz zu verwenden, ändern Sie Ihr Bewertungsrezept, indem Sie die folgenden Pflichtfelder hinzufügen, ohne die bestehende Konfiguration zu ändern:

```
evaluation:
 task: gen_qa
 strategy: gen_qa
 metric: all
```

## Einschränkungen

- Pro Bewertung ist nur eine `.jsonl`-Datei zulässig.
- Die Datei muss strikt dem definierten Schema folgen.

Bringen Sie Ihre eigenen Metriken mit

Sie können Ihre eigenen Metriken verwenden, um Ihren Workflow zur Modellevaluierung mit benutzerdefinierten Funktionen für die Vorverarbeitung, Nachverarbeitung und Metriken vollständig anzupassen. Die Vorverarbeitung ermöglicht es Ihnen, Eingabedaten zu verarbeiten, bevor sie an den Inferenzserver gesendet werden, und die Nachverarbeitung ermöglicht es Ihnen, die Metrikberechnung anzupassen und benutzerdefinierte Metriken an Ihre Bedürfnisse zurückzugeben.

Gehen Sie wie folgt vor, um Ihre eigenen Metriken mit dem benutzerdefinierten Evaluierungs-SDK zu erstellen.

1. Wenn Sie dies noch nicht getan haben, [erstellen Sie in Ihrem AWS-Konto ersten eine AWS Lambda Funktion](#).
2. Laden Sie die vorgefertigte `nova-custom-eval-layer.zip` Datei aus dem [GitHub Repository](#) herunter. Sie können dieses Open-Source-SDK für die benutzerdefinierte Evaluierung von Nova verwenden, um Eingabe- und Ausgabe-Payloads für Ihre benutzerdefinierte Funktion zu validieren und eine einheitliche Oberfläche für die Integration mit Novas Evaluierung von Bring Your Own Metrics während des Trainings bereitzustellen.
3. Laden Sie die benutzerdefinierte Lambda-Ebene mit dem folgenden Befehl hoch:

```
aws lambda publish-layer-version \
 --layer-name nova-custom-eval-layer \
 --zip-file fileb://nova-custom-eval-layer.zip \
 --compatible-runtimes python3.12 python3.11 python3.10 python3.9
```

4. Fügen Sie diese Ebene als benutzerdefinierte Ebene zu Ihrer Lambda-Funktion hinzu, zusammen mit der erforderlichen AWS Ebene: AWSLambdaPowerToolsPythonV3-python312-arm64 (für die pydantic Abhängigkeit erforderlich).
5. Aktualisieren Sie Ihren Lambda-Code anhand des bereitgestellten Beispiels und ändern Sie den Code nach Bedarf. Dieser Beispielcode erstellt eine Lambda-Funktion für die benutzerdefinierte Evaluierung von Nova mit Vor- und Nachverarbeitungsschritten für die Modellevaluierung.

```
from nova_custom_evaluation_sdk.processors.decorators import preprocess,
 postprocess
from nova_custom_evaluation_sdk.lambda_handler import build_lambda_handler

@preprocess
def preprocessor(event: dict, context) -> dict:
 data = event.get('data', {})
 return {
 "statusCode": 200,
 "body": {
 "system": data.get("system"),
 "prompt": data.get("prompt", ""),
 "gold": data.get("gold", "")
 }
 }

@postprocess
def postprocessor(event: dict, context) -> dict:
 # data is already validated and extracted from event
 data = event.get('data', [])
 inference_output = data.get('inference_output', '')
 gold = data.get('gold', '')

 metrics = []
 inverted_accuracy = 0 if inference_output.lower() == gold.lower() else 1.0
 metrics.append({
 "metric": "inverted_accuracy_custom",
 "value": accuracy
 })
```

```
Add more metrics here

return {
 "statusCode": 200,
 "body": metrics
}

Build Lambda handler
lambda_handler = build_lambda_handler(
 preprocessor=preprocessor,
 postprocessor=postprocessor
)
```

6. Gewähren Sie Lambda Zugriff auf den Evaluierungsjob. Stellen Sie sicher, dass die für den Evaluierungsjob angegebene Ausführungsrolle eine Richtlinie enthält, die Ihre Lambda-Funktion aufruft. Hier ist eine Beispielrichtlinie.

JSON

```
{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Sid": "LambdaAccess",
 "Effect": "Allow",
 "Action": [
 "lambda:InvokeFunction"
],
 "Resource": "arn:aws:lambda:us-east-1:111122223333:function:ExampleFunction",
 "Condition": {
 "StringLike": {
 "aws:PrincipalArn": "arn:aws:iam::111122223333:role/service-role/AmazonSageMaker-ExecutionRole-ARN"
 }
 }
 },
 {
 "Sid": "DenyNonAWSEventSourcesForLambda",
 "Effect": "Deny",
 "Action": [
```

```
 "lambda:InvokeFunction"
],
 "Resource": "arn:aws:lambda:us-east-1:111122223333:function:ExampleFunction",
 "Condition": {
 "Null": {
 "lambda:EventSourceToken": false
 }
 }
 }
]
}
```

7. Überprüfen Sie das Lambda-Payload-Schema. In der folgenden Tabelle ist das Lambda-Anforderungs- und Antwortschema aufgeführt. Sie können Ihr Schema mit dem benutzerdefinierten Evaluierungs-SDK von Nova validieren.

|               | Payload für Lambda-Anfragen                                                                                                                               | Payload für Lambda-Antworten                                                                                                                                                      |
|---------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Präprozessor  | <pre>{   "process_type": "preprocess",   "data": {     "system": "You are a helpful assistant",     "prompt": "What is 2+2?",     "gold": "4"   } }</pre> | <pre>{   "statusCode": 200,   "body": {     "system": "You are a helpful assistant that can substitute * for addition",     "prompt": "What is 2*2?",     "gold": "4"   } }</pre> |
| Postprozessor | <pre>{   "process_type": "postprocess",   "data": {     "prompt": "What is 2+2?",     "inference_output": "2+2=4",     "gold": "4"   } }</pre>            | <pre>{   "statusCode": 200,   "body": [     {"metric": "accuracy", "value": 1.0},     {"metric": "f1_score", "value": 1.0},     {"metric": "exact_match", "value": 1}   ] }</pre> |

|  | Payload für Lambda-Anfragen | Payload für Lambda-Antworten                                                 |
|--|-----------------------------|------------------------------------------------------------------------------|
|  | <pre>       }     } </pre>  | <pre>       {"metric": "length_ratio",        "value": 0.8}     ]   } </pre> |

## 8. Ändern Sie die Rezeptdatei. Ein Beispiel.

```

processor:
 lambda_arn: arn:aws:lambda:us-east-1:111122223333:function:name
 lambda_type: "custom_metrics"
 preprocessing:
 enabled: true
 postprocessing:
 enabled: true
 aggregation: average

```

- `lambda_arn`: Der Amazon-Ressourcenname (ARN) für Ihre Lambda-Funktion, die die Vor- und Nachverarbeitung übernimmt.
- `lambda_type`: „custom\_metrics“ oder „rft“.
- `preprocessing`: Ob benutzerdefinierte Vorverarbeitungsvorgänge aktiviert werden sollen.
- `postprocessing`: Ob benutzerdefinierte Nachverarbeitungsvorgänge aktiviert werden sollen.
- `aggregation`: Built-in Aggregationsfunktion (gültige Optionen: min, max, average, sum).

## Einschränkungen

- Bring Your Own Metrics gilt nur für Texteingabe-Datensätze.
- Multi-modal Eingabedatensätze werden nicht unterstützt.
- Der Vorverarbeitungsschritt verarbeitet das Metadatenfeld nicht.

## Benchmark-Rezepte für Nova LLM-as-a-Judge

### Important

`llm_judge` und `mm_llm_judge` kann nur für Amazon Nova-Basismodelle ausgeführt werden (z. B. `nova-micro/prod`, `nova-lite/prod`, `nova-pro/prod`, oder `nova-lite-2/prod`). Sie werden an Checkpoints für benutzerdefinierte Modelle nicht unterstützt.

`rubric_llm_judge` kann nur mit Amazon Nova 2.0-Basismodellen ausgeführt werden (z. B. `nova-lite-2/prod`). Es wird auf Amazon Nova 1.0-Basismodellen oder auf Checkpoints für benutzerdefinierte Modelle nicht unterstützt.

Um ein benutzerdefiniertes Modell mit einem Judge-Workflow zu evaluieren, verwenden Sie zunächst Ihr benutzerdefiniertes Modell, um den Prompt- und Response-Datensatz zu generieren, und führen Sie dann den Judge-Workflow anhand eines Amazon Nova-Basismodells aus, das diesen Datensatz als Eingabe verwendet.

Nova LLM Judge ist eine Modellbewertungsfunktion, mit der Sie die Qualität der Antworten eines Modells mit den Antworten eines Basismodells anhand eines benutzerdefinierten Datensatzes vergleichen können. Es akzeptiert einen Datensatz, der Eingabeaufforderungen, Basisantworten und Antworten von Herausforderern enthält, und verwendet dann ein Nova Judge-Modell, um durch paarweise Vergleiche eine Gewinnraten-Metrik bereitzustellen, die auf der [Bradley-Terry](#) Wahrscheinlichkeit basiert. Rezeptformat: `xxx_llm_judge_eval.yaml`.

## Anforderungen an den Nova-LLM-Datensatz

### Dateiformat:

- Eine einzige `llm_judge.jsonl`-Datei mit Bewertungsbeispielen. Der Dateiname sollte `llm_judge.jsonl` und kein anderer sein.
- Sie müssen Ihren Datensatz an einen S3-Standort hochladen, auf den SageMaker KI-Schulungsjobs zugreifen können.
- Die Datei muss dem für den `llm_judge`-Datensatz erforderlichen Schemaformat entsprechen.
- Der Eingabedatensatz sollte sicherstellen, dass alle Datensätze eine Kontextlänge von weniger als 12 000 haben.

Schemaformat – Jede Zeile in der `.jsonl`-Datei muss ein JSON-Objekt mit den folgenden Feldern sein.

- Pflichtfelder

`prompt`: Zeichenfolge, die den Prompt für die generierte Antwort enthält

`response_A`: Zeichenfolge, die die Basisantwort enthält



**response\_B:** Zeichenfolge, die die alternative Antwort enthält, die mit der Basisantwort verglichen wird

## Beispieleintrag

```
{
 "prompt": "What is the most effective way to combat climate change?",
 "response_A": "The most effective way to combat climate change is through a combination of transitioning to renewable energy sources and implementing strict carbon pricing policies. This creates economic incentives for businesses to reduce emissions while promoting clean energy adoption.",
 "response_B": "We should focus on renewable energy. Solar and wind power are good. People should drive electric cars. Companies need to pollute less."
}
{
 "prompt": "Explain how a computer's CPU works",
 "response_A": "CPU is like brain of computer. It does math and makes computer work fast. Has lots of tiny parts inside.",
 "response_B": "A CPU (Central Processing Unit) functions through a fetch-execute cycle, where instructions are retrieved from memory, decoded, and executed through its arithmetic logic unit (ALU). It coordinates with cache memory and registers to process data efficiently using binary operations."
}
{
 "prompt": "How does photosynthesis work?",
 "response_A": "Plants do photosynthesis to make food. They use sunlight and water. It happens in leaves.",
 "response_B": "Photosynthesis is a complex biochemical process where plants convert light energy into chemical energy. They utilize chlorophyll to absorb sunlight, combining CO2 and water to produce glucose and oxygen through a series of chemical reactions in chloroplasts."
}
```

Um Ihren benutzerdefinierten Datensatz zu verwenden, ändern Sie Ihr Bewertungsrezept mit den folgenden Pflichtfeldern, verändern Sie jedoch nicht den Inhalt:

```
evaluation:
 task: llm_judge
 strategy: judge
 metric: all
```

## Einschränkungen

- Pro Bewertung ist nur eine `.jsonl`-Datei zulässig.
- Die Datei muss strikt dem definierten Schema folgen.
- Die Nova-Judge-Modelle sind für die Spezifikationen von Micro, Lite und Pro identisch.
- Benutzerdefinierte Judge-Modelle werden derzeit nicht unterstützt.

## Nova LLM als Jurorin für multimodale (Bild-) Benchmark-Rezepte

Nova LLM Judge for multi-modal (Bild), kurz für Nova MM\_LLM Judge, ist eine Funktion zur Modellbewertung, mit der Sie die Qualität der Antworten eines Modells anhand eines benutzerdefinierten Datensatzes mit den Antworten eines Basismodells vergleichen können. Es akzeptiert einen Datensatz, der Eingabeaufforderungen, Basisantworten und Antworten der Herausforderer sowie Bilder in Form einer Base64-encoded Zeichenfolge enthält, und verwendet dann ein Nova Judge-Modell, um durch paarweise Vergleiche eine Gewinnratenmetrik bereitzustellen, die auf der Wahrscheinlichkeit basiert. [Bradley-Terry](#) Rezeptformat:

`xxx_mm_llm_judge_eval.yaml`.

## Anforderungen an den Nova-LLM-Datensatz

### Dateiformat:

- Eine einzige `mm_llm_judge.jsonl`-Datei mit Bewertungsbeispielen. Der Dateiname muss exakt sein. `llm_judge.jsonl`
- Sie müssen Ihren Datensatz an einen S3-Standort hochladen, an dem SageMaker KI-Schulungsjobs darauf zugreifen können.
- Die Datei muss dem für den `mm_llm_judge`-Datensatz erforderlichen Schemaformat entsprechen.
- Der Eingabedatensatz sollte sicherstellen, dass alle Datensätze eine Kontextlänge von weniger als 12 k haben, mit Ausnahme des Bildattributs.

Schemaformat – Jede Zeile in der `.jsonl`-Datei muss ein JSON-Objekt mit den folgenden Feldern sein.

- Pflichtfelder

`prompt`: Zeichenfolge, die den Prompt für die generierte Antwort enthält

**images:** Array, das eine Liste von Objekten mit Datenattributen enthält (Werte sind Base64-encoded Bildzeichenfolgen).

**response\_A:** Zeichenfolge, die die Basisantwort enthält

**response\_B:** Zeichenfolge, die die alternative Antwort enthält, die mit der Basisantwort verglichen wird

## Beispieleintrag

Aus Gründen der besseren Lesbarkeit enthält das folgende Beispiel neue Zeilen und Einrückungen, aber im eigentlichen Datensatz sollte sich jeder Datensatz in einer einzigen Zeile befinden.

```
{
 "prompt": "What is in the image?",
 "images": [
 {
 "data": "data:image/jpeg;base64,/9j/2wBDAAQDAwQDAwQEAwQFBAQFBgo..."
 }
],
 "response_A": "a dog.",
 "response_B": "a cat.",
}
{
 "prompt": "How many animals are in each of the images?",
 "images": [
 {
 "data": "data:image/jpeg;base64,/9j/2wBDAAQDAwQDAwQEAwQFBAQFBgo..."
 },
 {
 "data": "data:image/jpeg;base64,/DKEafe3gihn..."
 }
],
 "response_A": "The first image contains one cat and the second image contains one dog",
 "response_B": "The first image has one animal and the second has one animal"
}
```

Um Ihren benutzerdefinierten Datensatz zu verwenden, ändern Sie Ihr Bewertungsrezept mit den folgenden Pflichtfeldern, verändern Sie jedoch nicht den Inhalt:

```
evaluation:
 task: mm_llm_judge
 strategy: judge
 metric: all
```

## Einschränkungen

- Pro Bewertung ist nur eine `.jsonl`-Datei zulässig.
- Die Datei muss strikt dem definierten Schema folgen.
- Nova MM Judge-Modelle unterstützen nur Bildreferenzen.
- Die Nova MM Judge-Modelle sind in allen Spezifikationen von Amazon Nova Micro, Amazon Nova Lite und Amazon Nova Pro identisch.
- Benutzerdefinierte Judge-Modelle werden derzeit nicht unterstützt.
- Der Amazon S3 S3-Image-URI wird nicht unterstützt.
- Der Eingabedatensatz sollte sicherstellen, dass alle Datensätze eine Kontextlänge von weniger als 12 k haben, mit Ausnahme des Bildattributs.

## Auswertung von CPT-Checkpoints (Continuous Pre-Training)

Die Evaluierung anhand von CPT-Modellen (Continuous Pre-Trained) kann schwieriger sein als bei Modellen, die einer SFT (überwachte Feinabstimmung) unterzogen wurden, da CPT-Modelle regelmäßig nicht in der Lage sind, Anweisungen zu befolgen. Anstatt Anweisungen zu befolgen, fungiert das CPT-Modell als Abschlussmodell, d. h. es wird lediglich versucht, das in der Eingabe-Token-Sequenz enthaltene Muster fortzusetzen. Angesichts dieser Einschränkung funktionieren typische Bewertungsdatensätze aufgrund des „Q&A“-Formats der Eingaben möglicherweise nicht richtig. Anstatt die Frage zu beantworten, versucht das Modell einfach, dieselbe Frage weiterzuverfolgen. Wenn wir Datensätze jedoch auf eine bestimmte Art formatieren, um Modelle in einem Fertigstellungsstil aufzufordern, können wir uns ein Bild von der Leistung des Modells machen.

Folgen Sie den folgenden Schritten, um zu verstehen, wie Sie mithilfe des Nova Forge-Evaluierungsworkflows eine Evaluierung an einem kontinuierlichen, vortrainierten Modell durchführen können.

## Vorbereitung und Formatierung von Datensätzen

Bei der Bewertung eines CPT-Modells wird der bereits bestehende [Bring Your Own Dataset-Workflow](#) genutzt, der bereits im Rahmen der Modellevaluierung von Nova Forge zur Verfügung

gestellt wurde. Abfragen innerhalb des Datensatzes müssen jedoch in einem reinen Abschlussformat formatiert werden, da CPT-Modelle nicht auf die gleiche Weise auf Standardaufforderungen im Fragestil reagieren, wie dies bei einem SFT-Modell der Fall wäre.

Eine weitere wichtige häufige Einschränkung von Modellen, die ausschließlich einer CPT unterzogen wurden, ist ihre Unfähigkeit, STOP- oder End-of-Sequenz-Token zu generieren — das bedeutet, dass das Modell weiterhin Tokens generiert, bis es gewaltsam gestoppt wird (z. B. mit dem Parameter `max_new_tokens`). Angesichts dieser Einschränkung empfiehlt es sich, die Modelle anhand von Einzel-Token-Antworten (z. B. Multiple-Choice) zu bewerten, um sicherzustellen, dass das Modell nicht weiterhin Junk-Ausgaben generiert, die nach der Aufforderung nicht benötigt werden.

Beispielsweise könnte ein typischer Bewertungsdatensatz (wie MMLU, GPQA, MATH usw.) das Modell mit einer Frage wie der folgenden veranlassen:

```
Early settlements and high population density along coastlines and rivers are
best attributed to which of the following?
A: "Poor climate conditions"
B: "Limited forest cover"
C: "Cars"
D: "Access to trade routes"
```

(Expected answer is D.)

Ein CPT-Modell würde jedoch nicht verstehen, wie diese Frage richtig zu beantworten ist, da es keine Feinabstimmung bei der Befolgung von Anweisungen gibt. Aus diesem Grund müssen CPT-Modelle in einem Abschlussstil abgefragt werden, wie zum Beispiel:

```
Early settlements and high population density along coastlines and rivers
are best attributed to which of the following?
A: Poor climate conditions
B: Limited forest cover
C: Cars
D: Access to trade routes
The correct answer to this question is option
```

(Expected answer is D.)

Nach der Prüfung der Inferenz geben die vom Modell generierten Output-Logprobs Auskunft darüber, ob das Modell die Eingabe korrekt verarbeitet und die richtige Antwort generiert hat. Es kann nicht garantiert werden, dass das Modell immer genau die erwartete Antwort (in diesem Fall den

Buchstaben D) liefert. Wenn das Modell korrekt funktioniert, sollte sie jedoch in den Logprobs vorhanden sein.

Ein weiteres Beispiel für eine Eingabeaufforderung ohne Multiple-Choice-Vervollständigung

```
The capital of France is

(Expected answer of Paris)
```

Wir würden erwarten, dass das Modell entweder die Antwort „Paris“ ausgibt oder dass das Token, das „Paris“ entspricht, irgendwo in der Logprobs-Ausgabe erscheint.

### Formatierung von Datensätzen

Die CPT-Bewertung nutzt den bestehenden [Bring Your Own Dataset-Workflow](#). Die Daten müssen im Format „Query-Response“ in einer JSONL-Datei formatiert werden, die durch neue Zeilen getrennt ist.

Ein Beispiel für einen Datensatz mit 4 Einträgen:

```
{"query": "The capital of France is", "response": "Paris"}
{"query": "2 + 2 =", "response": "4"}
{"query": "The mitochondria is the powerhouse of the", "response": "cell"}
{"query": "What is the largest planet?\nA: Mars\nB: Jupiter\nC: Saturn\nD: Earth\n\nAnswer:", "response": "B"}
```

Jede Zeile muss enthalten:

- **query:** Der Text der Eingabeaufforderung zur Fertigstellung
- **response:** Die erwartete Fertigstellung (Ground Truth)

Das Modell erhält Rohtexteingaben ohne Chat-Formatierung. CPT-Modelle sind in der Regel noch nicht mit speziellen Tokens trainiert und reagieren nicht richtig auf Chat-Vorlagen. Wenn Sie also das Modell dazu auffordern, wird NUR die in der Abfrage angegebene Zeichenfolge an das Modell gesendet (mit einem zusätzlichen [BOS] Token, dem automatisch ein zusätzliches Token vorangestellt wird).

### Konfiguration des Rezepts

Hier ist ein Beispiel für ein Rezept, das für die Evaluierung eines CPT-Modells konfiguriert ist:

```
run:
 name: cpt_eval_job
 model_type: amazon.nova-2-lite-v1:0:256k
 model_name_or_path: s3://bucket/path/to/cpt-checkpoint/

evaluation:
 task: gen_qa # Required for CPT - bring your own dataset
 strategy: gen_qa
 metric: all # Returns rouge1, rouge2, rougeL, exact_match, f1_score, bleu

inference:
 checkpoint_is_instruction_tuned: "false" # Required for CPT checkpoints
 top_logprobs: 5 # Change to desired amount of logprobs to calculate
 max_new_tokens: 1 # Keep low for completion tasks
 temperature: 0.0
```

Die wichtigsten Änderungen bei der CPT-Bewertung:

- `checkpoint_is_instruction_tuned: "false"`

Dies ist ein neuer Parameter, der speziell zur Unterstützung von Testläufen an CPT-Checkpoints hinzugefügt wurde. Wenn `checkpoint_is_instruction_tuned` auf `false` gesetzt wird, wird die standardmäßige Amazon Nova-Chat-Vorlage deaktiviert, die normalerweise die Eingabeaufforderung umschließt.

- `top_logprobs: 5`

Log-Wahrscheinlichkeiten (logprobs) geben Aufschluss über die Vertrauensverteilung des Modells über die möglichen nächsten Tokens. So können Sie beurteilen, ob das Modell vor dem Training die erwarteten Ergebnisse erzielt hat. Wenn das Modell wie beabsichtigt funktioniert, sollten wir die erwartete Antwort (d. h. „A“, „B“ usw.) in der Regel entweder als generiertes Ausgabetoken oder als Token in den Logprobs betrachten.

- `max_new_tokens: 1`

CPT-Modelle wurden in der Regel noch nicht darauf trainiert, spezielle „Stop“ - oder „End of Sequence“ -Token zu generieren, um zu signalisieren, wann die Inferenz beendet werden muss. Das bedeutet, dass das Modell in der Regel weiterhin neue Token generiert, bis die spezifische maximale Token-Länge erreicht ist, was zu unnötigen Rückschlüssen führt. In der Regel ist es am effizientesten, die `max_new_tokens` auf 1 zu beschränken und eine Eingabeaufforderung bereitzustellen, mit der das Modell anhand einer einzigen Antwort bewertet werden kann (wie bei

einer Multiple-Choice-Frage). Wenn Sie `max_new_tokens` auf 1 setzen, wird sichergestellt, dass keine zusätzlichen Junk-Token generiert werden.

## Hauptparameter

- `checkpoint_is_instruction_tuned`: Muss auf (oder als boolescher Wert) gesetzt werden, um Chat-Vorlagen zu deaktivieren `"false" false`
- `top_logprobs`: 5, wird empfohlen, um zu sehen, wie das Modell während der CPT lernt
- Aufgabe: Muss sein `gen_qa` — CPT-Modelle können keine Benchmarks verwenden, bei denen Anweisungen befolgt werden, wie MMLU oder MATH
- Strategie: Muss sein `gen_qa`
- `max_new_tokens`: Es wird empfohlen, den Wert niedrig zu halten (1-5), da CPT-Modelle die Fertigstellung und nicht die Generierung durchführen

## Ausführen von Bewertungs-Trainingsjobs

Starten Sie einen Trainingsjob mit dem folgenden Beispielnotizbuch. Bitte sehen Sie sich das folgende Notizbuch als Beispiel für die Ausführung des Evaluierungs-Trainingsjobs an. Weitere Informationen finden Sie unter [Verwenden eines SageMaker KI-Schätzers zur Durchführung eines Trainingsjobs](#).

### Referenztabellen

Bevor Sie das Notebook ausführen, berücksichtigen Sie bei der Auswahl von Image-URI- und Instance-Konfigurationen die folgenden Referenztabellen.

#### Auswahl des Image-URI

| Rezept               | Image-URI                                                                                           |
|----------------------|-----------------------------------------------------------------------------------------------------|
| Bewertungs-Image-URI | <code>708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-TJ-Eval-V2-latest</code> |

#### Auswahl des Instance-Typs und der Anzahl von Instances



| Modell            | Job type                | Instance-Typ | Empfohlene Anzahl von Instances | Erlaubte Anzahl von Instances |
|-------------------|-------------------------|--------------|---------------------------------|-------------------------------|
| Amazon Nova Micro | Bewertung ()<br>SFT/DPO | g5.12xlarge  | 1                               | 1 - 16                        |
| Amazon Nova Lite  | Bewertung (SFT/<br>DPO) | g5.12xlarge  | 1                               | 1 - 16                        |
| Amazon Nova Pro   | Bewertung (SFT/<br>DPO) | p5.48xlarge  | 1                               | 1 - 16                        |
| Nova 2 Lite       | Bewertung (SFT/<br>DPO) | p5.48xlarge  | 1                               | 1 - 16                        |

## Beispiel-Notebook

Das folgende Beispiel-Notebook zeigt, wie ein Bewertungs-Trainingsjob ausgeführt wird.

```
install python SDK

Do not use sagemaker v3, as sagemaker v3 introduced breaking changes

!pip install sagemaker==2.254.1

import os
import sagemaker,boto3
from sagemaker.inputs import TrainingInput
from sagemaker.pytorch import PyTorch

sagemaker_session = sagemaker.Session()
role = sagemaker.get_execution_role()

Download recipe from https://github.com/aws/sagemaker-hyperpod-recipes/tree/main/
recipes_collection/recipes/evaluation/nova to local
Assume the file name be `recipe.yaml`

Populate parameters
```

```

input_s3_uri = "s3://<path>/input/" # (Optional) Only used for multi-modal dataset or
bring your own dataset s3 location
output_s3_uri= "s3://<path>/output/" # Output data s3 location, a zip containing
metrics json and tensorboard metrics files will be stored to this location
instance_type = "instance_type" # ml.g5.16xlarge as example
instance_count = 1 # The number of instances for inference (set instance_count > 1 for
multi-node inference to accelerate evaluation)
job_name = "your job name"
recipe_path = "recipe_path" # ./recipe.yaml as example
image_uri = "708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-TJ-
Eval-V2-latest" # Do not change
output_kms_key = "<KMS key arn to encrypt trained model in Amazon-owned S3 bucket>" #
optional, leave blank for Amazon managed encryption

(Optional) To bring your own dataset and LLM judge for evaluation
evalInput = TrainingInput(
s3_data=input_s3_uri,
distribution='FullyReplicated',
s3_data_type='S3Prefix'
#)

estimator = PyTorch(
 output_path=output_s3_uri,
 base_job_name=job_name,
 role=role,
 instance_type=instance_type,
 instance_count=instance_count,
 training_recipe=recipe_path,
 sagemaker_session=sagemaker_session,
 image_uri=image_uri,
 output_kms_key=output_kms_key
)
estimator.fit()

If input dataset exist, pass in inputs
estimator.fit(inputs={"train": evalInput})

```

## Auswertung und Analyse der Bewertungsergebnisse

Nach erfolgreichem Abschluss Ihres Bewertungsjobs können Sie die Ergebnisse anhand der folgenden Schritte bewerten und analysieren.

Gehen Sie wie folgt vor, um die Ergebnisse zu bewerten und zu analysieren.

1. Machen Sie sich mit der Struktur des Ausgabespeicherorts vertraut. Die Ergebnisse werden an Ihrem angegebenen Amazon-S3-Ausgabespeicherort als komprimierte Datei gespeichert:

```
s3://your-bucket/output/benchmark-name/
job_name/
 ### output/
 ### output.tar.gz
```

2. Laden Sie die `output.tar.gz`-Datei aus Ihrem Bucket herunter. Extrahieren Sie den Inhalt.

```
run_name/
eval_results/
| ### results_[timestamp].json
inference_output.jsonl (only present for gen_qa)
| ### details/
| ### model/
| ### <execution-date-time>/
| ###details_<task_name>_#_<datetime>.parquet
tensorboard_results/
 ### eval/
 ### events.out.tfevents.[timestamp]
```

- `results_[timestamp].json` – JSON-Datei mit den Ausgabemetriken
- `details_<task_name>_#_<datetime>.parquet` – Inferenz-Ausgabedatei (außer `strong_reject`)
- `events.out.tfevents.[timestamp]` – TensorBoard Ausgabedatei
- `inference_output.jsonl` – Bereinigte Inferenzausgabedatei (nur für `gen_qa`-Aufgaben)

3. Ergebnisse anzeigen in TensorBoard. So visualisieren Sie Ihre Bewertungsmetriken:

1. Laden Sie den extrahierten Ordner in einen S3-Bucket hoch.
2. Navigieren Sie zu SageMaker KI TensorBoard
3. Wählen Sie Ihre „S3-Ordner“.
4. Fügen Sie den S3-Ordnerpfad hinzu.
5. Warten Sie, bis die Synchronisation abgeschlossen ist.

4. Analysieren Sie die Inferenzausgaben. Alle Bewertungsaufgaben, mit Ausnahme von `llm_judge` und `strong_reject`, enthalten die folgenden Felder für die Analyse in der Inferenzausgabe.
- `full_prompt`- Die vollständige Benutzeraufforderung, die an das für die Bewertungsaufgabe verwendete Modell gesendet wird.
  - `gold`- Das Feld, das die richtige (n) Antwort (en) enthält, wie im Datensatz angegeben.
  - `metrics`- Das Feld, das die anhand der einzelnen Inferenz bewerteten Metriken enthält. Werte, die aggregiert werden müssen, haben keinen Wert in den einzelnen Inferenzausgaben.
  - `predictions`- Das Feld, das eine Liste der Modellausgaben für die angegebene Eingabeaufforderung enthält.
  - `pred_logits`- Das Feld, das die betrachteten Ausgabetokens und die Log-Wahrscheinlichkeiten jedes im Nachrichteninhalte zurückgegebenen Ausgabetokens enthält.

Anhand dieser Felder können Sie die Ursache für metrische Unterschiede ermitteln und das Verhalten der benutzerdefinierten Modelle verstehen.

Für `llm_judge` enthält die Inferenzausgabedatei die folgenden Felder unter dem Metrikfeld pro Bewertungspaar.

- `forward_output` – die reinen Präferenzen des Judge bei der Bewertung der Reihenfolge nach (`response_A`, `response_B`)
- `backward_output` – die reinen Präferenzen des Judge bei der Bewertung in umgekehrter Reihenfolge (`response_B`, `response_A`)
- `Pairwise metrics` – Metriken, die paarweise für Vorwärts- und Rückwärtsbeurteilungen berechnet werden, darunter `a_scores`, `b_scores`, `ties`, `inference-score` und `score`.

 Note

Aggregierte Metriken wie `winrate` sind nur in den zusammenfassenden Ergebnisdateien verfügbar, nicht nach individueller Beurteilung.

Für `gen_qa` enthält die Datei `inference_output.jsonl` die folgenden Felder für jedes JSON-Objekt:

- Prompt – der letzte Prompt, der an das Modell gesendet wurde
- Inferenz – die unformatierte Inferenzausgabe des Modells
- gold — Die Zielantwort aus dem Eingabedatensatz
- metadata — Die Metadatenzeichenfolge aus dem Eingabedatensatz, falls angegeben

## Bewährte Methoden zur Bewertung und Problembehebung

### Best Practices

Im Folgenden sind einige bewährte Verfahren für den Bewertungsprozess aufgeführt.

- Organisieren Sie Ihre Ausgabepfade nach Modell und Benchmark-Typ.
- Halten Sie konsistente Namenskonventionen ein, um die Nachverfolgung zu vereinfachen.
- Speichern Sie die extrahierten Ergebnisse an einem sicheren Ort.
- Überwachen Sie den TensorBoard Synchronisierungsstatus, ob die Daten erfolgreich geladen wurden.

### Fehlerbehebung

Sie können die CloudWatch Protokollgruppe `/aws/sagemaker/TrainingJobs` zum Trainieren von Job-Fehlerprotokollen verwenden.

### Ausfall des Motorkerns

Problem:

Wenn Sie Folgendes sehen:

```
RuntimeError: Engine core initialization failed.
```

Ursache:

Obwohl dies ein allgemeiner Fehler ist, der mehrere Ursachen haben kann, tritt er in der Regel auf, wenn zwischen dem Modell-Checkpoint, den Sie laden möchten, und dem angegebenen Modelltyp eine Diskrepanz besteht. E.g. Sie möchten einen fein abgestimmten Prüfpunkt für das Nova 2.0 Lite-Modell testen, aber der von Ihnen angegebene Modelltyp ist der Modelltyp 1.0. z. B. `amazon.nova-micro-v1:0:128k`

## Das richtige Mapping sollte

```
model_type: amazon.nova-2-lite-v1:0:256k
model_name_or_path: nova-lite-2/prod # or s3://escrow_bucket/model_location
```

### Vorbeugung:

Vergewissern Sie sich, `model_name_or_path` dass das auf der rechten Seite abgebildet ist, `model_type` bevor Sie den Bewertungsjob abschicken.

## Verfügbare Unteraufgaben

Im Folgenden sind die verfügbaren Unteraufgaben für die Modellevaluierung in mehreren Bereichen aufgeführt, darunter MMLU (Massive Multitask Language Understanding), BBH (Big Bench Hard), MATH und MMMU (Massive Multimodal Understanding). Multi-discipline Diese Unteraufgaben ermöglichen es Ihnen, die Leistung Ihres Modells in Bezug auf bestimmte Fähigkeiten und Wissensbereiche zu bewerten.

### MMLU

```
MMLU_SUBTASKS = [
 "abstract_algebra",
 "anatomy",
 "astronomy",
 "business_ethics",
 "clinical_knowledge",
 "college_biology",
 "college_chemistry",
 "college_computer_science",
 "college_mathematics",
 "college_medicine",
 "college_physics",
 "computer_security",
 "conceptual_physics",
 "econometrics",
 "electrical_engineering",
 "elementary_mathematics",
 "formal_logic",
 "global_facts",
 "high_school_biology",
 "high_school_chemistry",
 "high_school_computer_science",
```

```
"high_school_european_history",
"high_school_geography",
"high_school_government_and_politics",
"high_school_macroeconomics",
"high_school_mathematics",
"high_school_microeconomics",
"high_school_physics",
"high_school_psychology",
"high_school_statistics",
"high_school_us_history",
"high_school_world_history",
"human_aging",
"human_sexuality",
"international_law",
"jurisprudence",
"logical_fallacies",
"machine_learning",
"management",
"marketing",
"medical_genetics",
"miscellaneous",
"moral_disputes",
"moral_scenarios",
"nutrition",
"philosophy",
"prehistory",
"professional_accounting",
"professional_law",
"professional_medicine",
"professional_psychology",
"public_relations",
"security_studies",
"sociology",
"us_foreign_policy",
"virology",
"world_religions"
]
```

## BBH

```
BBH_SUBTASKS = [
 "boolean_expressions",
 "causal_judgement",
```

```

 "date_understanding",
 "disambiguation_qa",
 "dyck_languages",
 "formal_fallacies",
 "geometric_shapes",
 "hyperbaton",
 "logical_deduction_five_objects",
 "logical_deduction_seven_objects",
 "logical_deduction_three_objects",
 "movie_recommendation",
 "multistep_arithmetic_two",
 "navigate",
 "object_counting",
 "penguins_in_a_table",
 "reasoning_about_colored_objects",
 "ruin_names",
 "salient_translation_error_detection",
 "snarks",
 "sports_understanding",
 "temporal_sequences",
 "tracking_shuffled_objects_five_objects",
 "tracking_shuffled_objects_seven_objects",
 "tracking_shuffled_objects_three_objects",
 "web_of_lies",
 "word_sorting"
]

```

## Math (Mathematik)

```

MATH_SUBTASKS = [
 "algebra",
 "counting_and_probability",
 "geometry",
 "intermediate_algebra",
 "number_theory",
 "prealgebra",
 "precalculus",
]

```

## MMMU

```

MATH_SUBTASKS = [
 "Accounting",
]

```



```
"Agriculture",
"Architecture_and_Engineering",
"Art",
"Art_Theory",
"Basic_Medical_Science",
"Biology",
"Chemistry",
"Clinical_Medicine",
"Computer_Science",
"Design",
"Diagnostics_and_Laboratory_Medicine",
"Economics",
"Electronics",
"Energy_and_Power",
"Finance",
"Geography",
"History",
"Literature",
"Manage",
"Marketing",
"Materials",
"Math",
"Mechanical_Engineering",
"Music",
"Pharmacy",
"Physics",
"Psychology",
"Public_Health",
"Sociology",
```

Evaluieren Sie Ihre maßgeschneiderten Nova-Modelle mithilfe verschiedener Bewertungsmethoden und Metriken.

In diesem Abschnitt:

- [Bewertung des Argumentationsmodells](#)
- [RFT-Evaluierung](#)
- [Implementierung von Belohnungsfunktionen](#)

## Bewertung des Argumentationsmodells

### -Übersicht

Die Unterstützung von Argumentationsmodellen ermöglicht die Evaluierung mit Hilfe von Nova-Modellen, die eine explizite interne Argumentation durchführen, bevor endgültige Antworten generiert werden. Diese Funktion nutzt die Steuerung auf API-Ebene über den `reasoning_effort` Parameter, um die Argumentationsfunktion dynamisch zu aktivieren oder zu deaktivieren, wodurch möglicherweise die Antwortqualität bei komplexen Analyseaufgaben verbessert wird.

### Unterstützte Modelle

- `amazon.nova-2-lite-v 1:0:256 k`

### Konfiguration des Rezepts

Ermöglichen Sie die Argumentation, indem Sie den `reasoning_effort` Parameter zum `inference` Abschnitt Ihres Rezepts hinzufügen:

```
run:
 name: reasoning-eval-job-name # [MODIFIABLE] Unique
 identifier for your evaluation job
 model_type: amazon.nova-2-lite-v1:0:256k # [FIXED] Must be a reasoning-
supported model
 model_name_or_path: nova-lite-2/prod # [FIXED] Path to model
 checkpoint or identifier
 replicas: 1 # [MODIFIABLE] Number of
replicas for SageMaker Training job
 data_s3_path: "" # [MODIFIABLE] Leave empty for
SageMaker Training job; optional for SageMaker HyperPod job
 output_s3_path: "" # [MODIFIABLE] Output path for
SageMaker HyperPod job (not compatible with SageMaker Training jobs)

evaluation:
 task: mmlu # [MODIFIABLE] Evaluation task

 strategy: zs_cot # [MODIFIABLE] Evaluation
strategy
 metric: accuracy # [MODIFIABLE] Metric
calculation method

inference:
```

```
reasoning_effort: high # [MODIFIABLE] Enables
reasoning mode; options: low/high or null to disable
max_new_tokens: 32768 # [MODIFIABLE] Maximum tokens
to generate, recommended value when reasoning_effort set to high
top_k: -1 # [MODIFIABLE] Top-k sampling
parameter
top_p: 1.0 # [MODIFIABLE] Nucleus
sampling parameter
temperature: 0 # [MODIFIABLE] Sampling
temperature (0 = deterministic)
```

Verwenden Sie den Parameter `reasoning_effort`

Der `reasoning_effort` Parameter steuert das Argumentationsverhalten für Modelle, die zur Argumentation fähig sind.

Voraussetzungen

- Modellkompatibilität — `reasoning_effort` Nur festgelegt, wenn (derzeit) ein Modell `model_type` angegeben wird, das zu Argumenten fähig ist `amazon.nova-2-lite-v1:0:256k`
- Fehlerbehandlung — Die Verwendung `reasoning_effort` mit nicht unterstützten Modellen schlägt fehl mit `ConfigValidationError: "Reasoning mode is enabled but model '{model_type}' does not support reasoning. Please use a reasoning-capable model or disable reasoning mode."`

Verfügbare Optionen

| Option             | Behavior                                        | Token-Limit                         | Anwendungsfall                                                                                                         |
|--------------------|-------------------------------------------------|-------------------------------------|------------------------------------------------------------------------------------------------------------------------|
| null<br>(Standard) | Deaktiviert den<br>Argumentationsmodus          | –                                   | Standardauswertung<br>ohne Mehraufwand bei<br>der Argumentation                                                        |
| low                | Ermöglicht Argumentation<br>mit Einschränkungen | 4.000 Tokens für internes<br>Denken | Szenarien, die eine<br>präzise Argumentation<br>erfordern; optimiert im<br>Hinblick auf Geschwind<br>igkeit und Kosten |

| Option | Behavior                                      | Token-Limit                               | Anwendungsfall                                                                       |
|--------|-----------------------------------------------|-------------------------------------------|--------------------------------------------------------------------------------------|
| high   | Ermöglicht Argumentation ohne Einschränkungen | Keine Tokenbegrenzung für internes Denken | Komplexe Probleme, die umfangreiche Analysen und step-by-step Überlegungen erfordern |

| Trainingsmethode                       | Verfügbare Optionen    | Wie konfiguriert man                                                                                        |
|----------------------------------------|------------------------|-------------------------------------------------------------------------------------------------------------|
| SFT (überwachte Feinabstimmung)        | Nur hoch oder Aus      | Verwenden Sie reasoning_enabled: true (hoch) oder reasoning_enabled: false (off)                            |
| RFT (Feinabstimmung von Verstärkungen) | Niedrig, Hoch oder Aus | Verwenden Sie reasoning_effort: low oder reasoning_effort: high. Lassen Sie das zu deaktivierende Feld weg. |
| Bewertung                              | Niedrig, Hoch oder Aus | Verwenden Sie reasoning_effort: low oder reasoning_effort: high. Verwenden Sie null, um zu deaktivieren.    |

Wann sollte das Argumentieren aktiviert werden

Verwenden Sie den Argumentationsmodus (**low** oder **high**) für

- Komplexe Problemlösungsaufgaben (Mathematik, Logikrätsel, Programmieren)
- Mehrstufige analytische Fragen, die eine gründliche Argumentation erfordern
- Aufgaben, bei denen detaillierte Erklärungen oder step-by-step Überlegungen die Genauigkeit verbessern
- Szenarien, in denen die Qualität der Antworten Vorrang vor der Geschwindigkeit hat

Verwenden Sie den Modus ohne Argumentation (**null** oder lassen Sie den Parameter weg) für

- Einfache Fragen und Antworten oder sachliche Fragen
- Kreative Schreibaufgaben

- Wenn schnellere Reaktionszeiten entscheidend sind
- Leistungsbenchmarking, bei dem der Argumentationsaufwand ausgeschlossen werden sollte
- Kostenoptimierung, wenn Argumentation die Aufgabenleistung nicht verbessert

## Fehlerbehebung

Fehler: „Der Argumentationsmodus ist aktiviert, aber das Modell unterstützt kein Argumentieren“

Ursache: Der `reasoning_effort` Parameter ist auf einen Wert ungleich Null gesetzt, aber der angegebene Wert unterstützt `model_type` keine Argumentation.

## Auflösung

- Stellen Sie sicher, dass Ihr Modelltyp `amazon.nova-2-lite-v1:0:256k`
- Wenn Sie ein anderes Modell verwenden, wechseln Sie entweder zu einem Modell, das vernünftiges Denken ermöglicht, oder entfernen Sie den `reasoning_effort` Parameter aus Ihrem Rezept

## RFT-Evaluierung

Was ist eine RFT-Evaluierung?

Mit der RFT-Evaluierung können Sie die Leistung Ihres Modells mithilfe benutzerdefinierter Belohnungsfunktionen vor, während oder nach dem Reinforcement-Learning-Training bewerten. Im Gegensatz zu Standardbewertungen, die vordefinierte Metriken verwenden, können Sie mit RFT Evaluation Ihre eigenen Erfolgskriterien mithilfe einer Lambda-Funktion definieren, die Modellergebnisse auf der Grundlage Ihrer spezifischen Anforderungen bewertet.

Warum mit RFT evaluieren?

Die Bewertung ist entscheidend, um festzustellen, ob der RL-Feinabstimmungsprozess Folgendes beinhaltet:

- Verbesserte Abstimmung des Modells auf Ihren spezifischen Anwendungsfall und Ihre menschlichen Werte
- Beibehaltung oder Verbesserung der Modellfunktionen bei wichtigen Aufgaben
- Vermeidung unbeabsichtigter Nebenwirkungen wie verringerte Sachlichkeit, erhöhte Ausführlichkeit oder Leistungseinbußen bei anderen Aufgaben

- Hat Ihre benutzerdefinierten Erfolgskriterien erfüllt, wie sie in Ihrer Belohnungsfunktion definiert sind

Wann sollte die RFT-Evaluierung verwendet werden

Verwenden Sie die RFT-Evaluierung in diesen Szenarien:

- Vor dem RFT-Training: Legen Sie Basiskennzahlen für Ihren Bewertungsdatensatz fest
- Während des RFT-Trainings: Überwachen Sie den Trainingsfortschritt mit Zwischenstationen
- Nach dem RFT-Training: Stellen Sie sicher, dass das endgültige Modell Ihren Anforderungen entspricht
- Modelle vergleichen: Evaluieren Sie mehrere Modellversionen anhand einheitlicher Prämienkriterien

#### Note

Verwenden Sie RFT Evaluation, wenn Sie benutzerdefinierte, domänenspezifische Metriken benötigen. Verwenden Sie für allgemeine Bewertungsmethoden (Genauigkeit, Verwirrung, BLEU) die Standardauswertungsmethoden.

Datenformatanforderungen

Struktur der Eingabedaten

Die Eingabedaten der RFT-Bewertung müssen dem OpenAI Reinforcement Fine-Tuning-Format entsprechen. Jedes Beispiel ist ein JSON-Objekt, das Folgendes enthält:

- `messages`— Eine Reihe von Konversationswechseln mit `system` und Rollen `user`
- `reference_answer`— Erwartete Leistung oder Ground-Truth-Daten, die von Ihrer Belohnungsfunktion für die Bewertung verwendet werden

Beispiel für ein Datenformat

```
{
 "messages": [
 {
```

```

 "role": "user",
 "content": [
 {
 "type": "text",
 "text": "Solve for x. Return only JSON like {\"x\": <number>}. Equation: 2x +
5 = 13"
 }
]
 },
 "reference_answer": {
 "x": 4
 }
}

```

## Aktuelle Einschränkungen

- Nur Text: Es werden keine multimodalen Eingaben (Bilder, Audio, Video) unterstützt
- Single-Turn-Konversationen: Unterstützt nur Einzelbenutzernachrichten (keine Multi-Turn-Dialoge)
- JSON-Format: Die Eingabedaten müssen im JSONL-Format vorliegen (ein JSON-Objekt pro Zeile)
- Modellausgaben: Die Auswertung erfolgt anhand der generierten Vervollständigungen aus dem angegebenen Modell

## Vorbereitung Ihres Bewertungsrezepts

### Beispiel-Notebook

Ein vollständiges Beispiel finden Sie unter [Test-Notizbücher](#).

### Beispiel für eine Rezeptkonfiguration

```

run:
 name: nova-lite-rft-eval-job
 model_type: amazon.nova-lite-v1:0:300k
 model_name_or_path: s3://escrow_bucket/model_location # [MODIFIABLE] S3 path to your
model or model identifier
 replicas: 1 # [MODIFIABLE] For SageMaker Training jobs only; fixed for HyperPod jobs

 data_s3_path: "" # [REQUIRED FOR HYPERPOD] Leave empty for SageMaker Training jobs
and use TrainingInput in sagemaker python SDK
 output_s3_path: "" # [REQUIRED] Output artifact S3 path for evaluation results

```

```

evaluation:
 task: rft_eval # [FIXED] Do not modify
 strategy: rft_eval # [FIXED] Do not modify
 metric: all # [FIXED] Do not modify

Inference Configuration
inference:
 max_new_tokens: 8192 # [MODIFIABLE] Maximum tokens to generate
 top_k: -1 # [MODIFIABLE] Top-k sampling parameter
 top_p: 1.0 # [MODIFIABLE] Nucleus sampling parameter
 temperature: 0 # [MODIFIABLE] Sampling temperature (0 = deterministic)
 top_logprobs: 0 # [MODIFIABLE] Set between 1-20 to enable logprobs output

=====
Bring Your Own Reinforcement Learning Environment
=====
rl_env:
 reward_lambda_arn: arn:aws:lambda:<region>:<account_id>:function:<reward-function-name>

```

## Voreingestellte Belohnungsfunktionen

Zwei voreingestellte Belohnungsfunktionen (`prime_code` und `prime_math`) sind als Lambda-Schicht für eine einfache Integration in Ihre RFT-Lambda-Funktionen verfügbar.

### -Übersicht

Diese voreingestellten Funktionen bieten out-of-the-box Evaluierungsfunktionen für:

- `prime_code`— Codegenerierung und Korrektheitsbewertung
- `prime_math`— Mathematisches Denken und Bewertung der Problemlösung

### Quick Setup

1. Laden Sie die Lambda-Schicht aus den [nova-custom-eval-sdk Versionen](#) herunter.
2. Veröffentlichen Sie die Lambda-Ebene mit der AWS Befehlszeilenschnittstelle (AWS CLI):

```

aws lambda publish-layer-version \
 --layer-name preset-function-layer \
 --description "Preset reward function layer with dependencies" \

```



```
--zip-file fileb://universal_reward_layer.zip \
--compatible-runtimes python3.9 python3.10 python3.11 python3.12 \
--compatible-architectures x86_64 arm64
```

3. Fügen Sie die Ebene zu Ihrer Lambda-Funktion in der AWS Management Console hinzu (Wählen Sie die benutzerdefinierte Ebene preset-function-layer aus und fügen Sie AWSSDKPandas-Python 312 für numpy-Abhängigkeiten hinzu).
4. Importieren und in Ihrem Lambda-Code verwenden:

```
from prime_code import compute_score # For code evaluation
from prime_math import compute_score # For math evaluation
```

### prime\_code-Funktion

Evaluert Aufgaben zur Python-Codegenerierung, indem Code anhand von Testfällen ausgeführt und die Richtigkeit gemessen wird.

### Beispiel für ein Eingabedatensatzformat

```
{"messages":[{"role":"user","content":"Write a function that returns the sum of
two numbers."}], "reference_answer":{"inputs":["3\n5", "10\n-2", "0\n0"], "outputs":
["8", "8", "0"]}}
{"messages":[{"role":"user","content":"Write a function to check if a number
is even."}], "reference_answer":{"inputs":["4", "7", "0", "-2"], "outputs":
["True", "False", "True", "True"]}}
```

### Schlüssel-Features

- Automatische Codeextraktion aus Markdown-Codeblöcken
- Funktionserkennung und anrufbasiertes Testen
- Ausführung von Testfällen mit Timeout-Schutz
- Syntaxvalidierung und Kompilierungsprüfungen
- Detaillierte Fehlerberichterstattung mit Tracebacks

### prime\_math-Funktion

Evaluert die Fähigkeiten zum mathematischen Denken und zur Problemlösung mit Unterstützung symbolischer Mathematik.

## Eingabeformat

```
{"messages":[{"role":"user","content":"What is the derivative of $x^2 + 3x$?."}], "reference_answer": "2*x + 3"}
```

## Schlüssel-Features

- Symbolische mathematische Bewertung mit SymPy
- Mehrere Antwortformate (LaTeX, Klartext, symbolisch)
- Mathematische Äquivalenzprüfung
- Normalisierung und Vereinfachung von Ausdrücken

## Datenformatanforderungen

### Zur Codeauswertung

- Eingaben: Array von Funktionsargumenten (richtige Typen: Ganzzahlen, Zeichenketten usw.)
- Ausgaben: Array erwarteter Rückgabewerte (richtige Typen: Boolesche Werte, Zahlen usw.)
- Code: Muss in Python mit klaren Funktionsdefinitionen sein

### Für die mathematische Auswertung

- Referenzantwort: Mathematischer Ausdruck oder numerischer Wert
- Antwort: Kann LaTeX, Klartext oder symbolische Notation sein
- Äquivalenz: Wird symbolisch überprüft, nicht nur beim Abgleich von Zeichenketten

## Best Practices

- Verwenden Sie in Testfällen die richtigen Datentypen (Ganzzahlen im Vergleich zu Zeichenketten, boolesche Werte im Vergleich zu „True“)
- Sorgen Sie bei Codeproblemen für klare Funktionssignaturen
- Schließen Sie Grenzfälle in Testeingaben ein (Null, negative Zahlen, leere Eingaben)
- Formatieren Sie mathematische Ausdrücke konsistent in Referenzantworten
- Testen Sie Ihre Belohnungsfunktion vor der Bereitstellung mit Beispieldaten

## Fehlerbehandlung

Beide Funktionen beinhalten eine robuste Fehlerbehandlung für:

- Kompilierungsfehler im generierten Code
- Laufzeitausnahmen während der Ausführung
- Fehlerhaft formatierte Eingabedaten
- Timeout-Szenarien für Endlosschleifen
- Ungültige mathematische Ausdrücke

Erstellen Sie Ihre Belohnungsfunktion

Lambda-ARN-Anforderungen

Ihr Lambda-ARN muss diesem Format folgen:

```
"arn:aws:lambda:*:*:function:*SageMaker*"
```

Wenn das Lambda dieses Benennungsschema nicht hat, schlägt der Job mit dem folgenden Fehler fehl:

```
[ERROR] Unexpected error: lambda_arn must contain one of: ['SageMaker', 'sagemaker', 'Sagemaker'] when running on SMHP platform (Key: lambda_arn)
```

Lambda-Anforderungsformat

Ihre Lambda-Funktion empfängt Daten in diesem Format:

```
[
 {
 "id": "sample-001",
 "messages": [
 {
 "role": "user",
 "content": [
 {
 "type": "text",
 "text": "Do you have a dedicated security team?"
 }
]
 }
]
 },
]
```

```

 {
 "role": "nova_assistant",
 "content": [
 {
 "type": "text",
 "text": "As an AI developed by Company, I don't have a dedicated security
team..."
 }
]
 },
 {
 "role": "nova_assistant",
 "content": [
 {
 "type": "text",
 "text": "As an AI developed by Company, I do not have a traditional
security team..."
 }
]
 }
]
}

```

### Note

Die Nachrichtenstruktur umfasst das verschachtelte content Array, das dem Eingabedatenformat entspricht. Die letzte Nachricht mit Rolle nova\_assistant enthält die vom Modell generierte Antwort.

## Lambda-Antwortformat

Ihre Lambda-Funktion muss Daten in diesem Format zurückgeben:

```

[
 {
 "id": "sample-001",
 "aggregate_reward_score": 0.75,
 "metrics_list": [
 {
 "name": "accuracy",
 "value": 0.85,
 "type": "Metric"
 },
 {
 "name": "fluency",

```

```
 "value": 0.90,
 "type": "Reward"
 }
]
 }
]
```

## Antwortfelder

- **id**— Muss mit der eingegebenen Proben-ID übereinstimmen
- **aggregate\_reward\_score**— Gesamtpunktzahl (normalerweise 0,0 bis 1,0)
- **metrics\_list**— Reihe von Einzelmetriken mit:
  - **name**— Kennzahl der Metrik (z. B. „Genauigkeit“, „Fließfähigkeit“)
  - **value**— Metrischer Wert (typischerweise 0,0 bis 1,0)
  - **type**— Entweder „Metrik“ (für Berichte) oder „Belohnung“ (wird in Schulungen verwendet)

## IAM-Berechtigungen

### Erforderliche Berechtigungen

Ihre SageMaker Ausführungsrolle muss über Berechtigungen zum Aufrufen Ihrer Lambda-Funktion verfügen. Fügen Sie diese Richtlinie zu Ihrer SageMaker Ausführungsrolle hinzu:

```
{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Effect": "Allow",
 "Action": [
 "lambda:InvokeFunction"
],
 "Resource": "arn:aws:lambda:region:account-id:function:function-name"
 }
]
}
```

## Lambda-Ausführungsrolle

Die Ausführungsrolle Ihrer Lambda-Funktion benötigt grundlegende Lambda-Ausführungsberechtigungen:

```
{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Effect": "Allow",
 "Action": [
 "logs:CreateLogGroup",
 "logs:CreateLogStream",
 "logs:PutLogEvents"
],
 "Resource": "arn:aws:logs:*:*:*"
 }
]
}
```

Wenn Ihre Lambda-Funktion auf andere AWS Dienste zugreift (z. B. S3 für Referenzdaten, DynamoDB für die Protokollierung), fügen Sie diese Berechtigungen der Lambda-Ausführungsrolle hinzu.

### Ausführung des Evaluierungsjobs

1. Bereiten Sie Ihre Daten vor — Formatieren Sie Ihre Bewertungsdaten gemäß den Anforderungen an das Datenformat und laden Sie Ihre JSONL-Datei auf S3 hoch: `s3://your-bucket/eval-data/eval_data.jsonl`
2. Konfigurieren Sie Ihr Rezept — Aktualisieren Sie das Beispielrezept mit Ihrer Konfiguration:
  - Stellen Sie `model_name_or_path` den Standort Ihres Modells ein
  - Stellen `lambda_arn` Sie Ihre Belohnungsfunktion ARN ein
  - Stellen `output_s3_path` Sie den gewünschten Ausgabeort ein
  - Passen Sie die `inference` Parameter nach Bedarf an

Speichern Sie das Rezept unter `rft_eval_recipe.yaml`

3. Evaluierung ausführen — Führen Sie den Evaluierungsjob mit dem mitgelieferten Notizbuch aus: [Evaluierungs-Notebooks](#)
4. Fortschritt überwachen — Überwachen Sie Ihre Evaluierungsaufgabe durch:
  - SageMaker Konsole: Überprüfen Sie den Auftragsstatus und die Protokolle
  - CloudWatch Protokolle: Detaillierte Ausführungsprotokolle anzeigen
  - Lambda Logs: Probleme mit der Belohnungsfunktion debuggen

## Evaluierungsergebnisse verstehen

### Ausgabeformat

Der Evaluierungsjob gibt die Ergebnisse im JSONL-Format an Ihrem angegebenen S3-Speicherort aus. Jede Zeile enthält die Auswertungsergebnisse für eine Probe:

```
{
 "id": "sample-001",
 "aggregate_reward_score": 0.75,
 "metrics_list": [
 {
 "name": "accuracy",
 "value": 0.85,
 "type": "Metric"
 },
 {
 "name": "fluency",
 "value": 0.90,
 "type": "Reward"
 }
]
}
```

#### Note

Die Ausgabe des RFT-Evaluierungsjobs ist identisch mit dem Lambda Response-Format. Der Bewertungsservice durchläuft die Antwort Ihrer Lambda-Funktion unverändert und gewährleistet so die Konsistenz zwischen Ihren Belohnungsberechnungen und den Endergebnissen.

## Interpretation der Ergebnisse

### Gesamter Prämienwert

- Bereich: In der Regel 0,0 (am schlechtesten) bis 1,0 (am besten), hängt jedoch von Ihrer Implementierung ab
- Zweck: Eine einzelne Zahl, die die Gesamtleistung zusammenfasst
- Verwendungszweck: Modelle vergleichen, Verbesserungen im Vergleich zu Schulungen verfolgen

## Individuelle Metriken

- **Metriktyp:** Informationsmetriken für die Analyse
- **Art der Belohnung:** Metriken, die während des RFT-Trainings verwendet wurden
- **Interpretation:** Höhere Werte bedeuten im Allgemeinen eine bessere Leistung (es sei denn, Sie entwerfen inverse Metriken)

## Leistungsmaßstäbe

Was unter „guter“ Leistung zu verstehen ist, hängt von Ihrem Anwendungsfall ab:

| Punktebereich | Interpretation | Action                                                       |
|---------------|----------------|--------------------------------------------------------------|
| 0,8 - 1,0     | Ausgezeichnet  | Modell bereit für den Einsatz                                |
| 0,6 - 0,8     | Gut            | Geringfügige Verbesserungen können von Vorteil sein          |
| 0,4 - 0,6     | Fair           | Signifikante Verbesserung erforderlich                       |
| 0,0 - 0,4     | Schlecht       | Überprüfen Sie die Trainingsdaten und die Belohnungsfunktion |

### Important

Dies sind allgemeine Richtlinien. Definieren Sie Ihre eigenen Schwellenwerte auf der Grundlage der Geschäftsanforderungen, der Leistung des Basismodells, der domänenspezifischen Einschränkungen und der Kosten-Nutzen-Analyse von Weiterbildungsmaßnahmen.



## Fehlerbehebung

### Häufige Probleme

| Problem                   | Ursache                                  | Lösung                                                            |
|---------------------------|------------------------------------------|-------------------------------------------------------------------|
| Lambda-Zeitüberschreitung | Komplexe Prämienberechnung               | Lambda-Timeout erhöhen oder Funktion optimieren                   |
| Erlaubnis verweigert      | Fehlende IAM-Berechtigungen              | Stellen Sie sicher, dass die SageMaker Rolle Lambda aufrufen kann |
| Inkonsistente Ergebnisse  | Nichtdeterministische Belohnungsfunktion | Verwenden Sie feste Ausgangswerte oder deterministische Logik     |
| Fehlende Ergebnisse       | Lambda-Fehler wurden nicht erkannt       | Fügen Sie eine umfassende Fehlerbehandlung in Lambda hinzu        |

### Checkliste zum Debuggen

- Stellen Sie sicher, dass die Eingabedaten bei verschachtelten Inhaltsarrays das richtige Format haben
- Bestätigen Sie, dass der Lambda-ARN korrekt ist und die Funktion bereitgestellt wurde
- Überprüfen Sie die IAM-Berechtigungen für den SageMaker → Lambda-Aufruf
- Überprüfen Sie die CloudWatch Protokolle auf Lambda-Fehler
- Überprüfen Sie, ob die Lambda-Antwort dem erwarteten Format entspricht

### Best Practices

- Einfach starten: Beginnen Sie mit den grundlegenden Belohnungsfunktionen und wiederholen Sie den Vorgang
- Lambda separat testen: Verwenden Sie Lambda-Testereignisse vor der vollständigen Auswertung
- Bei kleinem Datensatz validieren: Führen Sie die Auswertung für eine Teilmenge vor dem vollständigen Datensatz durch

- Versionskontrolle: Verfolgen Sie die Versionen der Belohnungsfunktionen zusammen mit den Modellversionen
- Kosten überwachen: Lambda-Aufrufe und Rechenzeit wirken sich auf die Kosten aus
- Umfangreich protokollieren: Verwenden Sie Print-Anweisungen in Lambda zum Debuggen
- Richten Sie die Timeouts angemessen ein: Balance zwischen Geduld und Kosten
- Dokumentieren Sie Kennzahlen: Definieren Sie klar, was jede Metrik misst

## Nächste Schritte

Nach Abschluss der RFT-Evaluierung:

- Wenn die Ergebnisse zufriedenstellend sind: Modell in der Produktion einsetzen
- Falls eine Verbesserung erforderlich ist:
  - Passen Sie die Belohnungsfunktion an
  - Sammle mehr Trainingsdaten
  - Ändern Sie die Trainingshyperparameter
  - Führen Sie zusätzliche RFT-Trainingsiterationen aus
- Kontinuierliche Überwachung: Regelmäßige Neubewertung anhand neuer Daten

## Implementierung von Belohnungsfunktionen

### -Übersicht

Die Belohnungsfunktion (auch Scorer oder Grader genannt) ist die Kernkomponente, die Modellantworten auswertet und Feedbacksignale für das Training liefert. Sie muss als Lambda-Funktion implementiert werden, die Modellantworten akzeptiert und Belohnungspunkte zurückgibt.

### Format der Schnittstelle

Ihre Prämienfunktion muss Daten im folgenden Format akzeptieren und zurückgeben:

Beispiel für ein Eingabebeispiel für das Training

```
{
 "messages": [
 {
 "role": "user",
```

```

 "content": "Do you have a dedicated security team?"
 },
],
 "reference_answer": {
 "compliant": "No",
 "explanation": "As an AI developed by Company, I do not have a traditional
security team..."
 }
}

```

### Beispielnutzlast für das Belohnungs-Lambda

Der Container transformiert Ihre Daten automatisch, bevor er sie an Ihre Lambda-Funktion sendet, indem er:

1. Generieren einer Modellantwort für jede Aufforderung
2. Der Turn des Assistenten (generierte Antwort) wird an das Nachrichten-Array angehängt
3. Ein eindeutiges `id` Feld für die Nachverfolgung hinzufügen

Ihre Lambda-Funktion empfängt Daten in diesem transformierten Format:

```

{
 "id": "123",
 "messages": [
 {
 "role": "user",
 "content": "Do you have a dedicated security team?"
 },
 {
 "role": "assistant",
 "content": "As an AI developed by Amazon, I don not have a dedicated
security team..."
 }
],
 # Following section will be same as your training dataset sample
 "reference_answer": {
 "compliant": "No",
 "explanation": "As an AI developed by Company, I do not have a traditional
security team..."
 }
}

```

## Lambda-Vertrag belohnen

```
def lambda_handler(event, context):
 return lambda_grader(event)

def lambda_grader(samples: list[dict]) -> list[dict]:
 """
 Args:
 samples: List of dictionaries in OpenAI format

 Example input:
 {
 "id": "123",
 "messages": [
 {
 "role": "user",
 "content": "Do you have a dedicated security team?"
 },
 {
 "role": "assistant",
 "content": "As an AI developed by Company, I don nott have a
dedicated security team..."
 }
],
 # This section will be same as your training dataset
 "reference_answer": {
 "compliant": "No",
 "explanation": "As an AI developed by Company, I do not have a
traditional security team..."
 }
 }

 Returns:
 List of dictionaries with reward scores:
 {
 "id": str, # Same id as input sample
 "aggregate_reward_score": float, # Overall score for the sample
 "metrics_list": [# OPTIONAL: Component scores
 {
 "name": str, # Name of the component score
 "value": float, # Value of the component score
 "type": str # "Reward" or "Metric"
 }
]
 }
```

```
}
 ""
```

## Eingabe- und Ausgabefelder

### Eingabefelder

| Feld                       | Description                                                 | Weitere Hinweise                                                   |
|----------------------------|-------------------------------------------------------------|--------------------------------------------------------------------|
| id                         | Eindeutiger Bezeichner für die Probe                        | In der Ausgabe wiedergegeben.<br>Zeichenkettenformat               |
| messages                   | Chatverlauf im OpenAI-Format bestellt                       | Reihe von Nachrichtenobjekten                                      |
| nachrichten<br>[] .role    | Sprecher der Nachricht                                      | Allgemeine Werte: „Benutzer“, „Assistent“, „System“                |
| nachrichten<br>[] .content | Textinhalt der Nachricht                                    | Einfache Zeichenfolge                                              |
| **Metadaten                | Informationen in freier Form zur Unterstützung der Benotung | Objekt; optionale Felder, die aus Trainingsdaten übernommen wurden |

### Ausgabefelder

| Feld                       | Description                                                          | Weitere Hinweise                                       |
|----------------------------|----------------------------------------------------------------------|--------------------------------------------------------|
| id                         | Derselbe Bezeichner wie beim Eingabebeispiel                         | Muss mit der Eingabe übereinstimmen                    |
| aggregate<br>_reward_score | Gesamtpunktzahl für die Stichprobe                                   | Float (z. B. 0,0—1,0 oder aufgabendefinierter Bereich) |
| metrics_list               | Die Werte der Komponenten, aus denen sich das Aggregat zusammensetzt | Anordnung metrischer Objekte                           |

## Technische Einschränkungen

- Timeout-Limit — maximale Ausführungszeit von 15 Minuten pro Lambda-Aufruf
- Parallelität — Muss gleichzeitige Anfragen bearbeiten `rollout_worker_replicas * 64`
- Zuverlässigkeit — Muss eine angemessene Fehlerbehandlung implementieren und konsistent gültige Ergebnisse zurückgeben
- Leistung — Optimiere für eine schnelle Ausführung (Sekunden, nicht Minuten), um effizientes Training zu ermöglichen

## Best Practices

- Minimiere externe API-Aufrufe
- Verwenden Sie effiziente Algorithmen und Datenstrukturen
- Implementieren Sie eine Wiederholungslogik für vorübergehende Fehler
- Wiederverwendbare Berechnungen zwischenspeichern
- Testen Sie vor dem Training gründlich, um eine fehlerfreie Ausführung sicherzustellen

## Verwenden von benutzerdefinierten Belohnungsfunktionen

Implementieren Sie benutzerdefinierte Belohnungsfunktionen, wenn Sie aufgabenspezifische Bewertungskriterien haben:

- Definieren Sie Bewertungskriterien — Ermitteln Sie, was eine gute Antwort auf Ihre Aufgabe ausmacht
- Lambda-Funktion implementieren — Erstellen Sie eine Lambda-Funktion im Schnittstellenformat
- Lokal testen — Stellen Sie sicher, dass Ihre Funktion korrekte Werte für Beispieleingaben zurückgibt
- Bereitstellen auf AWS — Stellen Sie Ihr Lambda bereit und notieren Sie sich den ARN
- Rezept konfigurieren — Fügen Sie den Lambda-ARN zum Feld Ihres Rezepts `reward_lambda_arn` hinzu
- Test mit kleinem Datensatz — Führen Sie RFT mit minimalen Daten aus, um die Integration zu überprüfen

## IAM-Berechtigungen

### Erforderliche Berechtigungen

Ihre SageMaker Ausführungsrolle muss über Berechtigungen zum Aufrufen Ihrer Lambda-Funktion verfügen. Fügen Sie diese Richtlinie zu Ihrer SageMaker Ausführungsrolle hinzu:

```
{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Effect": "Allow",
 "Action": [
 "lambda:InvokeFunction"
],
 "Resource": "arn:aws:lambda:region:account-id:function:function-name"
 }
]
}
```

### Lambda-Ausführungsrolle

Die Ausführungsrolle Ihrer Lambda-Funktion benötigt grundlegende Lambda-Ausführungsberechtigungen:

```
{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Effect": "Allow",
 "Action": [
 "logs:CreateLogGroup",
 "logs:CreateLogStream",
 "logs:PutLogEvents"
],
 "Resource": "arn:aws:logs:*:*:*"
 }
]
}
```

**Zusätzliche Berechtigungen:** Wenn Ihre Lambda-Funktion auf andere AWS Dienste zugreift (z. B. S3 für Referenzdaten, DynamoDB für die Protokollierung), fügen Sie diese Berechtigungen der Lambda-Ausführungsrolle hinzu.

### Beispiel: LLM als Prämienfunktion für Richter

Dieses Beispiel zeigt, wie Amazon Bedrock-Modelle als Richter verwendet werden, um Modellantworten zu bewerten, indem sie mit Referenzantworten verglichen werden. Diese Lambda-Vorlage bietet Kunden ein Framework, mit dem sie Aufrufe an Amazon Bedrock für Inferenzanfragen zur Verarbeitung von Richterbeurteilungen implementieren können. Die Lambda-Funktion behält den gleichen input/output Vertrag wie andere Belohnungsfunktionen bei.

### Implementierung

Diese Lambda-Funktion implementiert einen zweistufigen Bewertungsprozess: Sie `lambda_handler` extrahiert Modellantworten und Referenzantworten aus eingehenden Stichproben. Anschließend ruft die `lambda_graded` Funktion Amazon Bedrock auf, um die semantische Ähnlichkeit zwischen ihnen zu bewerten. Die Implementierung umfasst eine robuste Fehlerbehandlung mit automatischen Wiederholungsversuchen bei vorübergehenden Fehlern und unterstützt flexible Referenzantwortformate (sowohl Zeichenketten- als auch strukturierte Wörterbuchformate).

### Einzelheiten der Implementierung:

- **Retry Logic:** Implementiert exponentielles Backoff (1s, 2s, 4s) zur Drosselung von Ausnahmen, um Bedrock-API-Ratenbegrenzungen zu umgehen
- **Fehlerbehandlung:** Gibt für fehlgeschlagene Auswertungen einen Wert von 0,0 zurück, anstatt Ausnahmen auszulösen
- **Deterministische Bewertung:** Verwendet Temperatur=0,0, um konsistente Ergebnisse bei allen Bewertungen sicherzustellen
- **Flexibles Referenzformat:** Verarbeitet automatisch Antworten auf Zeichenketten und Wörterbuchreferenzen
- **Punktebegrenzung:** Stellt sicher, dass alle Ergebnisse innerhalb des gültigen Bereichs [0,0, 1,0] liegen
- **Modellunabhängig:** Ändern Sie `JUDGE_MODEL_ID`, um ein beliebiges Amazon Bedrock-Modell (Nova, Llama, Mistral usw.) zu verwenden



```

"""
LLM Judge Lambda POC - Working implementation using Amazon Bedrock
"""

import json
import time
import boto3

bedrock_runtime = boto3.client('bedrock-runtime', region_name='us-east-1')
JUDGE_MODEL_ID = "anthropic.claude-3-5-sonnet-20240620-v1:0"
SYSTEM_PROMPT = "You must output ONLY a number between 0.0 and 1.0. No explanations, no
 text, just the number."

JUDGE_PROMPT_TEMPLATE = """Compare the following two responses and rate how similar
 they are on a scale of 0.0 to 1.0, where:
- 1.0 means the responses are semantically equivalent (same meaning, even if worded
 differently)
- 0.5 means the responses are partially similar
- 0.0 means the responses are completely different or contradictory

Response A: {response_a}

Response B: {response_b}

Output ONLY a number between 0.0 and 1.0. No explanations."""

def lambda_graded(response_a: str, response_b: str, max_retries: int = 3) -> float:
 """Call Bedrock to compare responses and return similarity score."""
 prompt = JUDGE_PROMPT_TEMPLATE.format(response_a=response_a, response_b=response_b)

 for attempt in range(max_retries):
 try:
 response = bedrock_runtime.converse(
 modelId=JUDGE_MODEL_ID,
 messages=[{"role": "user", "content": [{"text": prompt}]}],
 system=[{"text": SYSTEM_PROMPT}],
 inferenceConfig={"temperature": 0.0, "maxTokens": 10}
)
 print(f"Bedrock call successful: {response}")
 output = response['output']['message']['content'][0]['text'].strip()
 score = float(output)

```

```

 print(f"Score parsed: {score}")
 return max(0.0, min(1.0, score))

 except Exception as e:
 if "ThrottlingException" in str(e) and attempt < max_retries - 1:
 time.sleep(2 ** attempt)
 else:
 print(f"Bedrock call failed: {e}")
 return None
 return None

def lambda_handler(event, context):
 """AWS Lambda handler - processes samples from RFTEvalInvoker."""
 try:
 samples = event if isinstance(event, list) else [event]
 results = []

 for sample in samples:
 sample_id = sample.get("id", "unknown")
 messages = sample.get("messages", [])

 # Extract assistant response (response A)
 response_a = ""
 for msg in messages:
 if msg.get("role") in ["assistant", "nova_assistant"]:
 response_a = msg.get("content", "")
 break

 # Extract reference answer from root level (no longer in metadata)
 reference_answer = sample.get("reference_answer", "")

 # Handle both string and dict reference_answer formats
 if isinstance(reference_answer, dict):
 # If reference_answer is a dict, extract the explanation or compliant
 response_b = reference_answer.get("explanation",
 reference_answer.get("compliant", ""))
 else:
 response_b = reference_answer

 if not response_a or not response_b:
 results.append({
 "id": sample_id,

```

```

 "aggregate_reward_score": 0.0,
 "metrics_list": [{"name": "similarity_score", "value": 0.0, "type":
"Metric"}]
 })
 continue

 # Get similarity score
 score = lambda_graded(response_a, response_b)

 results.append({
 "id": sample_id,
 "aggregate_reward_score": score,
 "metrics_list": [
 {
 "name": "similarity_score",
 "value": score,
 "type": "Metric"
 }
]
 })

 return {"statusCode": 200, "body": json.dumps(results)}

except Exception as e:
 print(f"Error: {e}")
 return {"statusCode": 500, "body": json.dumps({"error": str(e)})}

```

## Eingabeformat

Das Lambda erhält dasselbe Eingabeformat wie andere Belohnungsfunktionen:

```

{
 "id": "sample-001",
 "messages": [
 {
 "role": "user",
 "content": "Do you have a dedicated security team?"
 },
 {
 "role": "assistant",
 "content": "As an AI developed by Amazon, I don't have a dedicated security
team..."
 }
],

```

```
"reference_answer": {
 "compliant": "No",
 "explanation": "As an AI developed by Company, I do not have a traditional
security team..."
},
"my_custom_field": "custom_value"
}
```

## Ausgabeformat

```
{
 "id": "sample-001",
 "aggregate_reward_score": 0.85,
 "metrics_list": [
 {
 "name": "similarity_score",
 "value": 0.85,
 "type": "Metric"
 }
]
}
```

## Überlegungen zur Bereitstellung

Möglicherweise müssen Sie auch die Eingabeaufforderungsvorlage und die Inferenzparameter an die Funktionen und das API-Format Ihres ausgewählten Modells anpassen.

- IAM-Berechtigungen: Die Lambda-Ausführungsrolle muss über `bedrock:InvokeModel` Berechtigungen für das von Ihnen gewählte Modell verfügen
- Timeout: Legen Sie das Lambda-Timeout auf mindestens 60 Sekunden fest, um der Bedrock-API-Latenz und den Wiederholungsversuchen Rechnung zu tragen
- Region: In einer Region einsetzen, in der das von Ihnen gewählte Bedrock-Modell verfügbar ist
- Kosten: Überwachen Sie die Bedrock-API-Nutzung, da bei jeder Evaluierung ein API-Aufruf pro Probe erfolgt
- Durchsatz: Fordern Sie für umfangreiche Evaluationen erhöhte Bedrock-Kontingente an, um Drosselungen zu vermeiden

## Erhöhung des Durchsatzes im Grundgestein

Wenn Sie während der Evaluierung eine Drosselung feststellen, erhöhen Sie die Kontingente für Ihr Bedrock-Modell:

- Navigieren Sie zur AWS Service Quotas Quotas-Konsole.
- Suchen Sie nach „Bedrock“ und wählen Sie Ihre Region aus
- Finden Sie das Kontingent für das von Ihnen gewählte Modell heraus (zum Beispiel „Aufrufe pro Minute für Claude 3.5 Sonnet“)
- Klicken Sie auf „Erhöhung des Kontingents beantragen“ und geben Sie den gewünschten Durchsatz an
- Begründen Sie die Erhöhung (z. B. „Arbeitsaufwand bei der RFT-Evaluierung“)

Die integrierte Wiederholungslogik von Lambda verarbeitet gelegentliche Drosselungen, aber dauerhaft umfangreiche Auswertungen erfordern angemessene Quotenerhöhungen.

Erforderliche IAM-Richtlinie:

```
{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Effect": "Allow",
 "Action": [
 "bedrock:InvokeModel"
],
 "Resource": "arn:aws:bedrock:*::foundation-model/*"
 }
]
}
```

## Iteratives Training

Iteratives Training ist ein systematischer Ansatz zur Feinabstimmung von Modellen durch mehrere Trainingszyklen, wobei jede Runde auf dem vorherigen Checkpoint aufbaut, indem spezifische Schwächen behoben werden, die bei der Bewertung entdeckt wurden. Diese Methode ermöglicht gezielte Verbesserungen der Modellleistung durch die Einbeziehung kuratierter Beispiele, die sich mit Fehlerarten befassen, die Anpassung an sich ändernde Anforderungen und die schrittweise Validierung von Verbesserungen, anstatt sich auf einen einzigen langen Trainingslauf festzulegen. Der Prozess folgt in der Regel Mustern wie SFT (Supervised Fine-Tuning) gefolgt von RFT (Reward-

based Fine-Tuning), wobei Checkpoints in S3-Buckets mit AWS verwalteten Escrow-S3-Buckets gespeichert werden, auf die für nachfolgende Trainingsiterationen verwiesen werden kann, wobei die Konsistenz von Modelltyp und Trainingstechnik während der gesamten Pipeline gewahrt bleibt.

Weitere Informationen finden Sie unter [???](#).

## Amazon Nova-Anpassung auf SageMaker HyperPod

Sie können Amazon Nova-Modelle, einschließlich der erweiterten Amazon Nova 2.0-Modelle, mithilfe von [Amazon Nova-Rezepten](#) anpassen und sie auf Hyperpod trainieren. Ein Rezept ist eine YAML-Konfigurationsdatei, die der SageMaker KI Einzelheiten zur Ausführung Ihrer Modellanpassung zur Verfügung stellt. SageMaker HyperPod unterstützt zwei Arten von Diensten: Forge und Non-forge.

Hyperpod bietet Hochleistungsdatenverarbeitung mit optimierten GPU-Instances und Amazon FSx for Lustre-Speicher, robuste Überwachung durch Integration mit Tools wie flexiblem Checkpoint-Management für iterative Verbesserungen TensorBoard, nahtlose Bereitstellung auf Amazon Bedrock für Inferenz und effizientes, skalierbares verteiltes Training mit mehreren Knoten — alles zusammen bietet Unternehmen eine sichere, leistungsstarke und flexible Umgebung, in der sie Amazon Nova-Modelle an ihre spezifischen Geschäftsanforderungen anpassen können.

Amazon Nova-Anpassung an SageMaker HyperPod speichert Modellartefakte, einschließlich Modell-Checkpoints, in einem serviceverwalteten Amazon S3 S3-Bucket. Artefakte im vom Service verwalteten Bucket sind mit Schlüsseln verschlüsselt. SageMaker AI-managed AWS KMS Service-managed Amazon S3 S3-Buckets unterstützen derzeit keine Datenverschlüsselung mit kundenverwalteten KMS-Schlüsseln. Sie können diesen Checkpoint-Standort für Bewertungsjobs oder Amazon-Bedrock-Inferenz verwenden.

Standardpreise können für Datenverarbeitungs-Instances, Amazon-S3-Speicher und FSx für Lustre gelten. Preisinformationen finden Sie unter [Hyperpod-Preise](#), [Amazon S3 S3-Preise](#) und [FSx for Lustre-Preise](#).

## Rechenanforderungen für Amazon Nova 2-Modelle

In den folgenden Tabellen sind die Rechenanforderungen SageMaker HyperPod und die Ausbildung von SageMaker KI-Schulungsjobs für Amazon Nova 2-Modelle zusammengefasst.

## Nova 2-Schulungsanforderungen

| Trainings<br>technik                                           | Minimale<br>Anzahl von<br>Instanzen | Instance-Typ | Anzahl der<br>GPUs | Hinweise                                                                           | Unterstützte<br>Modelle |
|----------------------------------------------------------------|-------------------------------------|--------------|--------------------|------------------------------------------------------------------------------------|-------------------------|
| SFT (LoRa)                                                     | 4                                   | P5.48xlarge  | 16                 | Parameter<br>-efficient<br>Feinabsti<br>mmung                                      | Nova 2 Lite             |
| SFT (voller<br>Rang)                                           | 4                                   | P5.48xlarge  | 32                 | Vollständ<br>ige Feinabsti<br>mmung des<br>Modells                                 | Nova 2 Lite             |
| RFT für<br>SageMaker<br>Ausbildun<br>gsberufe<br>(LoRa)        | 2                                   | P5.48xlarge  | 16                 | Benutzerd<br>efinierte<br>Belohnung<br>sfunktion<br>en in Ihrer<br>Umgebung<br>AWS | Nova 2 Lite             |
| RFT für<br>SageMaker<br>Ausbildun<br>gsberufe<br>(voller Rang) | 4                                   | P5.48xlarge  | 32                 | Länge des<br>Kontextes<br>von 32 KB                                                | Nova 2 Lite             |
| RFT ein<br>SageMaker<br>HyperPod                               | 8                                   | P5.48xlarge  | 64                 | Standardk<br>ontextlänge<br>8192                                                   | Nova 2 Lite             |
| CPT                                                            | 4                                   | P5.48xlarge  | 16                 | Verarbeit<br>et ungefähr<br>400 Millionen<br>Token pro                             | Nova 2 Lite             |

| Trainings<br>technik | Minimale<br>Anzahl von<br>Instanzen | Instance-Typ | Anzahl der<br>GPUs | Hinweise           | Unterstützte<br>Modelle |
|----------------------|-------------------------------------|--------------|--------------------|--------------------|-------------------------|
|                      |                                     |              |                    | Instanz und<br>Tag |                         |

Um Ihre Workflows zur Anpassung Ihrer Amazon Nova-Modelle auf Hyperpod zu optimieren, befolgen Sie diese empfohlenen Best Practices für effizientes Training, Ressourcenmanagement und erfolgreiche Modellbereitstellung.

## Bewährte Methoden für die Anpassung von Amazon Nova

### -Übersicht

Dieser Abschnitt bietet einen Überblick über Anpassungstechniken und hilft Ihnen bei der Auswahl des besten Ansatzes für Ihre Bedürfnisse und verfügbaren Daten.

#### Zwei Phasen der LLM-Ausbildung

Das Training mit großen Sprachmodellen besteht aus zwei Hauptphasen: vor dem Training und nach dem Training. Vor dem Training verarbeitet das Modell Tokens mit Rohtext und optimiert es für die Vorhersage des nächsten Tokens. Dieser Prozess erstellt einen Mustervervollständiger, der Syntax, Semantik, Fakten und Argumentationsmuster aus dem Internet und kuratiertem Text aufnimmt. Das vortrainierte Modell versteht jedoch Anweisungen, Benutzerziele oder kontextgerechtes Verhalten nicht. Es setzt den Text in dem Stil fort, der zu seiner Schulungsstruktur passt. Ein vorab trainiertes Modell vervollständigt die Anweisungen automatisch, statt sie zu befolgen, erzeugt eine inkonsistente Formatierung und kann unerwünschte Verzerrungen oder unsichere Inhalte aus den Trainingsdaten wiedergeben. Pre-training fördert die allgemeine Kompetenz, nicht den Nutzen einer Aufgabe.

Post-training verwandelt den Mustervervollständiger in einen nützlichen Assistenten. Sie führen mehrere Runden von Supervised Fine-Tuning (SFT) durch, um dem Modell beizubringen, Anweisungen zu befolgen, Schemata und Richtlinien einzuhalten, Tools aufzurufen und zuverlässige Ergebnisse zu erzielen, indem Sie hochwertige Demonstrationen imitieren. Durch diese Ausrichtung lernt das Modell, auf Eingabeaufforderungen als Aufgaben und nicht als Text zu reagieren, um fortzufahren. Anschließend wenden Sie Reinforcement Fine-Tuning (RFT) an, um das Verhalten mithilfe von messbarem Feedback (z. B. Prüfer oder einem LLM-as-a-judge) zu optimieren, wobei Kompromisse wie Genauigkeit und Kürze, Sicherheit und Umfang oder mehrstufiges Denken unter



Berücksichtigung von Einschränkungen abgewogen werden. In der Praxis wechseln Sie SFT und RFT zyklisch ab, um aus dem vorab trainierten Modell ein zuverlässiges, richtliniengerechtes System zu machen, das komplexe Aufgaben konsistent ausführt.

## Wählen Sie den richtigen Anpassungsansatz

In diesem Abschnitt werden wir uns mit Strategien zur Anpassung nach dem Training befassen: RFT und SFT.

### Feinabstimmung der Verstärkung (RFT)

Die Feinabstimmung der Verstärkung verbessert die Modellleistung durch Feedbacksignale — messbare Werte oder Belohnungen, die auf die Qualität der Antworten hinweisen — und nicht durch direkte Überwachung mit exakt richtigen Antworten. Im Gegensatz zur herkömmlichen überwachten Feinabstimmung, die aus Input-Output-Paaren lernt, verwendet RFT Belohnungsfunktionen, um die Modellantworten zu bewerten, und optimiert das Modell iterativ, um diese Belohnungen zu maximieren. Dieser Ansatz eignet sich gut für Aufgaben, bei denen es schwierig ist, den exakt richtigen Output zu definieren, aber Sie können die Qualität der Antworten zuverlässig messen. RFT ermöglicht es Modellen, komplexe Verhaltensweisen und Präferenzen durch Ausprobieren und Feedback zu erlernen, und eignet sich daher ideal für Anwendungen, die eine differenzierte Entscheidungsfindung, kreative Problemlösung oder die Einhaltung bestimmter Qualitätskriterien erfordern, die Sie programmgesteuert bewerten können. Die Beantwortung komplexer Rechtsfragen ist beispielsweise ein idealer Anwendungsfall für RFT, da Sie dem Modell beibringen möchten, besser zu argumentieren, um Fragen genauer zu beantworten.

### Funktionsweise

Bei der Feinabstimmung von Verstärkungen gehen Sie von einer auf Anweisungen abgestimmten Ausgangsbasis aus und behandeln jede Aufforderung wie ein kleines Turnier. Für eine bestimmte Eingabe nehmen Sie eine Stichprobe von einer Handvoll Kandidatenantworten aus dem Modell, bewerten jede einzelne mit der Belohnungsfunktion und ordnen sie dann innerhalb dieser Gruppe ein. Durch den Aktualisierungsschritt wird das Modell dahingehend verändert, dass beim nächsten Mal die Wahrscheinlichkeit von Kandidaten mit einer höheren Punktzahl steigt und die Wahrscheinlichkeit von Kandidaten mit niedrigerer Punktzahl verringert wird, während eine Beschränkung, die nahe am Ausgangswert bleibt, verhindert, dass das Verhalten abdriftet, ausführlich oder ausbeuterisch wird. Sie wiederholen diese Schleife bei vielen Eingabeaufforderungen, aktualisieren schwierige Fälle, verschärfen die Prüfer- oder Richterrubriken, wenn Sie Exploits sehen, und verfolgen kontinuierlich Aufgabenmetriken.

## Wann sollte RFT verwendet werden

Aufgaben, die am meisten von RFT profitieren, haben mehrere Merkmale gemeinsam. Sie haben messbare Erfolgssignale, auch wenn es schwierig ist, eine einzelne korrekte Ausgabe zu spezifizieren. Sie geben teilweise Anerkennung oder benotete Qualität, sodass Sie innerhalb einer Aufforderung oder mithilfe einer Belohnungsfunktion bessere oder schlechtere Antworten bewerten können. Sie beinhalten mehrere Ziele, die gegeneinander abgewogen werden müssen (z. B. Genauigkeit und Kürze, Klarheit, Sicherheit oder Kosten). Sie erfordern die Einhaltung ausdrücklicher Einschränkungen, die Sie programmgesteuert überprüfen können. Sie funktionieren in toolgestützten oder umgebungsbasierten Umgebungen, in denen Ergebnisse beobachtbar sind (Erfolg oder Misserfolg, Latenz, Ressourcennutzung). Sie treten in Ländern auf, in denen das Sammeln von Goldzielen teuer ist, aber automatisiertes oder rubrikbasiertes Feedback in Hülle und Fülle vorhanden ist. RFT funktioniert am besten, wenn Sie Qualität in einen zuverlässigen Skalar oder ein zuverlässiges Ranking umwandeln können und möchten, dass das Modell Verhaltensweisen mit höheren Punktzahlen bevorzugt verstärkt, ohne dass erschöpfende, beschriftete Ziele erforderlich sind.

Ziehen Sie in folgenden Fällen andere Methoden in Betracht:

- Sie haben zahlreiche, zuverlässig beschriftete Eingangs-/Ausgangspaare — verwenden Sie SFT
- Die größte Lücke ist Wissen oder Fachjargon — nutzen Sie Retrieval-Augmented Generation (RAG)
- Dein Belohnungssignal ist verrauscht oder unzuverlässig und du kannst es nicht mit besseren Rubriken oder Checkern beheben. Stabilisiere das zuerst, bevor du RFT

## Wann sollte RFT nicht verwendet werden

Vermeiden Sie RFT in diesen Situationen:

- Sie können kostengünstig zuverlässige, beschriftete Eingangs-/Ausgangspaare herstellen (SFT ist einfacher, billiger und stabiler)
- Die Lücke ist eher Wissen oder Fachjargon als Verhalten (verwenden Sie RAG)
- Ihr Belohnungssignal ist laut, spärlich, einfach zu spielen oder teuer oder langsam zu berechnen (korrigieren Sie zuerst den Evaluator)
- Die Ausgangsleistung liegt nahe Null (zuerst mit SFT starten, bevor die Einstellungen optimiert werden)

- Die Aufgabe hat deterministische Schemata, eine strikte Formatierung oder eine einzige richtige Antwort (SFT oder regelbasierte Validierung funktioniert besser)
- Enge Latenz- oder Kostenbudgets können die zusätzlichen Probenahme- oder Explorationskosten, die RFT erfordert, nicht auffangen
- Sicherheits- oder politische Einschränkungen sind in der Prämie nicht klar spezifiziert und durchsetzbar

Wenn Sie auf „die richtige Antwort“ hinweisen können, verwenden Sie SFT. Wenn Sie neues Wissen benötigen, verwenden Sie RAG. Verwenden Sie RFT erst, wenn Sie über eine solide Ausgangsbasis und eine robuste, schnelle und schwer zu nutzende Belohnungsfunktion verfügen.

### Überwachte Optimierung (SFT)

Die überwachte Feinabstimmung trainiert das LLM anhand eines Datensatzes von von Menschen beschrifteter Input-Output-Paare für Ihre Aufgabe. Sie geben Beispiele für Eingabeaufforderungen (Fragen, Anweisungen usw.) mit den richtigen oder gewünschten Antworten und setzen das Training des Modells anhand dieser Beispiele fort. Das Modell passt seine Gewichtungen an, um einen überwachten Verlust zu minimieren (in der Regel eine Kreuzentropie zwischen seinen Vorhersagen und den Ziel-Output-Token). Dabei handelt es sich um dasselbe Training, das bei den meisten Aufgaben des überwachten maschinellen Lernens zur Spezialisierung eines LLM verwendet wird.

SFT verändert Verhalten, nicht Wissen. Es bringt dem Modell keine neuen Fakten oder Fachausdrücke bei, die es vor dem Training nicht gesehen hat. Es bringt dem Modell bei, wie man antwortet, nicht, was es wissen soll. Wenn Sie neues Fachwissen benötigen (z. B. interne Terminologie), verwenden Sie Retrieval-Augmented Generation (RAG), um diesen Kontext zum Zeitpunkt der Inferenz bereitzustellen. SFT fügt dann das gewünschte Verhalten bei der Befolgung von Anweisungen hinzu.

### Funktionsweise

SFT optimiert LLM, indem es den durchschnittlichen Kreuzentropieverlust bei Antwort-Token minimiert, Prompt-Token als Kontext behandelt und sie vor dem Verlust maskiert. Das Modell verinnerlicht Ihren Zielstil, Ihre Struktur und Ihre Entscheidungsregeln und lernt, für jede Aufforderung die richtige Antwort zu generieren. Um Dokumente beispielsweise in benutzerdefinierte Kategorien zu klassifizieren, optimieren Sie das Modell mithilfe von Eingabeaufforderungen (dem Dokumenttext) und beschrifteten Vervollständigungen (den Kategoriebeschriftungen). Sie trainieren mit diesen Paaren, bis das Modell für jede Aufforderung mit hoher Wahrscheinlichkeit die richtige Bezeichnung ausgibt.

Sie können SFT mit nur ein paar hundert Beispielen durchführen und bis zu einigen hunderttausend skalieren. SFT-Proben müssen von hoher Qualität sein und direkt auf das gewünschte Modellverhalten abgestimmt sein.

### Wann sollte SFT verwendet werden

Verwenden Sie SFT, wenn Sie eine klar definierte Aufgabe mit eindeutig gewünschten Ergebnissen haben. Wenn Sie explizit angeben können, dass „Bei gegebener X-Eingabe ist die richtige Ausgabe Y“ und Beispiele für solche Zuordnungen sammeln können, ist die überwachte Feinabstimmung eine gute Wahl. SFT zeichnet sich in diesen Szenarien aus:

- Strukturierte oder komplexe Klassifizierungsaufgaben — Klassifizieren Sie interne Dokumente oder Verträge in viele benutzerdefinierte Kategorien. Mit SFT lernt das Modell diese spezifischen Kategorien besser kennen, als wenn es nur Eingabeaufforderungen erfordert.
- Question-answering oder Transformationsaufgaben mit bekannten Antworten — Fine-tune ein Modell zur Beantwortung von Fragen aus der Wissensdatenbank eines Unternehmens oder zur Konvertierung von Daten zwischen Formaten, bei denen jede Eingabe eine korrekte Antwort hat.
- Einheitlichkeit bei Formatierung und Stil — Trainieren Sie das Modell so, dass es immer in einem bestimmten Format oder Ton reagiert, indem Sie anhand von Beispielen für das richtige Format oder den richtigen Ton Feinabstimmungen vornehmen. Wenn das Modell beispielsweise anhand von Paaren zwischen Aufforderung und Antwort trainiert wird, die eine bestimmte Markensprache zum Ausdruck bringen, wird dem Modell beigebracht, Outputs mit diesem Stil zu generieren. Instruction-following Verhalten wird häufig zunächst durch SFT anhand von kuratierten Beispielen für gutes Assistenzverhalten vermittelt.

SFT ist der direkteste Weg, einem LLM eine neue Fähigkeit oder ein neues Verhalten beizubringen, wenn Sie angeben können, wie das richtige Verhalten aussieht. Es nutzt das vorhandene Sprachverständnis des Modells und konzentriert es auf Ihre Aufgabe. Verwenden Sie SFT, wenn Sie möchten, dass das Modell eine bestimmte Aufgabe erfüllt und Sie einen Datensatz mit Beispielen haben oder erstellen können.

Verwenden Sie SFT, wenn Sie qualitativ hochwertige Eingabeaufforderungs- und Antwortpaare zusammenstellen können, die das gewünschte Verhalten genau widerspiegeln. Es eignet sich für Aufgaben mit klaren Zielen oder deterministischen Formaten wie Schemas, Funktions- oder Toolaufrufen sowie für strukturierte Antworten, bei denen Nachahmung ein geeignetes Trainingssignal ist. Das Ziel ist die Verhaltensgestaltung: Dem Modell beizubringen, Eingabeaufforderungen als Aufgaben zu behandeln, Anweisungen zu befolgen, Ton- und

Ablehnungsrichtlinien anzunehmen und eine einheitliche Formatierung zu gewährleisten. Planen Sie mindestens Hunderte von Demonstrationen ein, bei denen Datenqualität, Konsistenz und Deduplizierung wichtiger sind als das reine Volumen. Für ein unkompliziertes, kosteneffizientes Update sollten Sie parametereffiziente Methoden wie Low-Rank Adaptation verwenden, um kleine Adapter zu trainieren und dabei den Großteil des Backbones unangetastet zu lassen.

Wann sollte SFT nicht verwendet werden

Verwenden Sie SFT nicht, wenn die Lücke eher im Wissen als im Verhalten besteht. Es vermittelt dem Modell keine neuen Fakten, Fachjargon oder aktuelle Ereignisse. Verwenden Sie in diesen Fällen die Generierung mit erweitertem Abruf, um externes Wissen als Inferenz heranzuziehen. Vermeiden Sie SFT, wenn Sie die Qualität messen können, aber keine einzige richtige Antwort angeben können. Verwenden Sie die Feinabstimmung der Verstärkung mit überprüfbaren Belohnungen oder einer, um diese Prämien LLM-as-a-judge direkt zu optimieren. Wenn sich Ihre Bedürfnisse oder Inhalte häufig ändern, verlassen Sie sich auf den Abruf und die Verwendung von Tools, anstatt das Modell erneut zu trainieren.

Themen

- [Nova Forge SDK](#)
- [Erstellen eines SageMaker HyperPod EKS-Clusters mit eingeschränkter Instanzgruppe \(RIG\)](#)
- [Leitfaden SageMaker HyperPod für Amazon Essential Commands](#)
- [Zugang und Einrichtung von Nova Forge für](#)
- [Schulung für Amazon Nova-Modelle](#)
- [Bewerten Ihres trainierten Modells](#)
- [Überwachung von Jobs mit MLflow HyperPod](#)

## Nova Forge SDK

Das Amazon Nova Forge SDK ist ein umfassendes Python-SDK, das eine einheitliche, programmatische Oberfläche für den gesamten Lebenszyklus der Amazon Nova-Modellanpassung bietet. Das SDK vereinfacht die Modellanpassung, indem es eine einzige, konsistente API für Training, Bewertung, Überwachung, Bereitstellung und Inferenz auf den Plattformen Amazon SageMaker und Amazon Bedrock bietet.

Weitere Informationen finden Sie unter [Nova Forge SDK](#).

# Erstellen eines SageMaker HyperPod EKS-Clusters mit eingeschränkter Instanzgruppe (RIG)

Um ein Modell auf Hyperpod anzupassen, muss die erforderliche Infrastruktur eingerichtet werden. Einzelheiten zur Einrichtung eines SageMaker HyperPod EKS-Clusters mit einer eingeschränkten Instanzgruppe (RIG) finden Sie im [Workshop](#), der eine detaillierte Anleitung zum Einrichtungsprozess bietet.

## Leitfaden SageMaker HyperPod für Amazon Essential Commands

Amazon SageMaker HyperPod bietet umfangreiche Befehlszeilenfunktionen für die Verwaltung von Schulungsabläufen. Dieses Handbuch behandelt grundlegende Befehle für allgemeine Operationen, von der Verbindung mit Ihrem Cluster bis hin zur Überwachung des Auftragsfortschritts.

### Voraussetzungen

Bevor Sie diese Befehle verwenden, stellen Sie sicher, dass Sie die folgende Einrichtung abgeschlossen haben:

- SageMaker HyperPod Cluster mit erstelltem RIG (normalerweise in us-east-1)
- Ausgabe eines Amazon S3 S3-Buckets, der für Trainingsartefakte erstellt wurde
- Mit entsprechenden Berechtigungen konfigurierte IAM-Rollen
- Trainingsdaten wurden im richtigen JSONL-Format hochgeladen
- Die FSx for Lustre-Synchronisierung ist abgeschlossen (beim ersten Job in den Cluster-Protokollen überprüfen)

### Themen

- [Recipe CLI installieren](#)
- [Verbindungsaufbau mit Ihrem Cluster](#)
- [Einen Ausbildungsjob beginnen](#)
- [Jobstatus wird überprüft](#)
- [Jobprotokolle überwachen](#)
- [Aktive Jobs auflisten](#)
- [Stornieren eines Auftrags](#)

- [Einen Evaluierungsjob ausführen](#)
- [Häufige Probleme](#)

## Recipe CLI installieren

Navigieren Sie zum Stammverzeichnis Ihres Rezept-Repositorys, bevor Sie den Installationsbefehl ausführen.

Verwenden Sie das Hyperpodrecipes-Repository, wenn Sie Anpassungstechniken verwenden, die nicht von Forge stammen. Informationen zur Forge-basierten Anpassung finden Sie im Forge-spezifischen Rezept-Repository.

Führen Sie die folgenden Befehle aus, um die SageMaker HyperPod CLI zu installieren:

### Note

Stellen Sie sicher, dass Sie sich nicht in einer aktiven Conda/Anaconda/Miniconda-Umgebung oder einer anderen virtuellen Umgebung befinden

Wenn ja, verlassen Sie die Umgebung bitte mit:

- `conda deactivate` für Conda/Anaconda/Miniconda-Umgebungen
- `deactivate` für virtuelle Python-Umgebungen

Wenn Sie eine Technik zur Anpassung verwenden, die nicht von Forge stammt, laden Sie die Sagemaker-Hyperpod-Rezepte wie unten gezeigt herunter:

```
git clone -b release_v2 https://github.com/aws/sagemaker-hyperpod-cli.git
cd sagemaker-hyperpod-cli
pip install -e .
cd ..
root_dir=$(pwd)
export PYTHONPATH=${root_dir}/sagemaker-hyperpod-cli/src/hyperpod_cli/
sagemaker_hyperpod_recipes/launcher/nemo/nemo_framework_launcher/launcher_scripts:
$PYTHONPATH
curl -fsSL -o get_helm.sh https://raw.githubusercontent.com/helm/helm/main/scripts/get-helm-3
chmod 700 get_helm.sh
```

```
./get_helm.sh
rm -f ./get_helm.sh
```

Wenn Sie ein Forge-Abonnent sind, sollten Sie die Rezepte mithilfe des unten genannten Verfahrens herunterladen.

```
mkdir NovaForgeHyperpodCLI
cd NovaForgeHyperpodCLI
aws s3 cp s3://nova-forge-c7363-206080352451-us-east-1/v1/ ./ --recursive
pip install -e .

curl -fsSL -o get_helm.sh https://raw.githubusercontent.com/helm/helm/main/scripts/get-helm-3
chmod 700 get_helm.sh
./get_helm.sh
rm -f ./get_helm.sh
```

#### Tip

Um vor der Ausführung eine [neue virtuelle Umgebung](#) zu verwenden, führen Sie folgenden Befehl aus:

- `python -m venv nova_forge`
- `source nova_forge/bin/activate`
- In Ihrer Befehlszeile wird nun (nova\_forge) am Anfang Ihrer Eingabeaufforderung angezeigt
- Dadurch wird sichergestellt, dass bei der Verwendung der CLI keine konkurrierenden Abhängigkeiten bestehen.

Zweck: Warum tun wir das `pip install -e .`?

Dieser Befehl installiert die SageMaker HyperPod CLI im bearbeitbaren Modus, sodass Sie aktualisierte Rezepte verwenden können, ohne sie jedes Mal neu installieren zu müssen. Außerdem können Sie neue Rezepte hinzufügen, die von der CLI automatisch abgerufen werden können.

## Verbindungsaufbau mit Ihrem Cluster

Connect die SageMaker HyperPod CLI mit Ihrem Cluster, bevor Sie Jobs ausführen:



```
export AWS_REGION=us-east-1 && SageMaker HyperPod connect-cluster --cluster-name
<your-cluster-name> --region us-east-1
```

### Important

Dieser Befehl erstellt eine Kontextdatei (`/tmp/hyperpod_context.json`), die für nachfolgende Befehle erforderlich ist. Wenn Sie eine Fehlermeldung darüber erhalten, dass diese Datei nicht gefunden wurde, führen Sie den Befehl `connect` erneut aus.

Profi-Tipp: Sie können Ihren Cluster weiter so konfigurieren, dass er immer den `kubeflow` Namespace verwendet, indem Sie das `--namespace kubeflow` Argument wie folgt zu Ihrem Befehl hinzufügen:

```
export AWS_REGION=us-east-1 && \
hyperpod connect-cluster \
--cluster-name <your-cluster-name> \
--region us-east-1 \
--namespace kubeflow
```

Dies erspart Ihnen den Aufwand, das `-n kubeflow` bei der Interaktion mit Ihren Jobs in jedem Befehl hinzufügen zu müssen.

## Einen Ausbildungsjob beginnen

### Note

Wenn Sie PPO/RFT Jobs ausführen, stellen Sie sicher, dass Sie Labelauswahl-Einstellungen hinzufügen, `src/hyperpod_cli/sagemaker_hyperpod_recipes/recipes_collection/cluster/k8s.yaml` sodass alle Pods auf demselben Knoten geplant sind.

```
label_selector:
 required:
 sagemaker.amazonaws.com/instance-group-name:
 - <rig_group>
```

Starten Sie einen Trainingsjob mithilfe eines Rezepts mit optionalen Parameterüberschreibungen:

```
hyperpod start-job -n kubeflow \
--recipe fine-tuning/nova/nova_1_0/nova_micro/SFT/nova_micro_1_0_p5_p4d_gpu_lora_sft \
--override-parameters '{
"instance_type": "ml.p5.48xlarge",
 "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-
HP-SFT-latest"
}'
```

Erwartete Ausgabe:

```
Final command: python3 <path_to_your_installation>/NovaForgeHyperpodCLI/src/
hyperpod_cli/sagemaker_hyperpod_recipes/main.py recipes=fine-tuning/nova/
nova_micro_p5_gpu_sft cluster_type=k8s cluster=k8s base_results_dir=/local/home/
<username>/results cluster.pullPolicy="IfNotPresent" cluster.restartPolicy="OnFailure"
 cluster.namespace="kubeflow" container="708977205387.dkr.ecr.us-east-1.amazonaws.com/
nova-fine-tune-repo:HP-SFT-DATAMIX-latest"
```

```
Prepared output directory at /local/home/<username>/results/<job-name>/k8s_templates
Found credentials in shared credentials file: ~/.aws/credentials
Helm script created at /local/home/<username>/results/<job-name>/<job-name>_launch.sh
Running Helm script: /local/home/<username>/results/<job-name>/<job-name>_launch.sh
```

```
NAME: <job-name>
LAST DEPLOYED: Mon Sep 15 20:56:50 2025
NAMESPACE: kubeflow
STATUS: deployed
REVISION: 1
TEST SUITE: None
Launcher successfully generated: <path_to_your_installation>/NovaForgeHyperpodCLI/src/
hyperpod_cli/sagemaker_hyperpod_recipes/launcher/nova/k8s_templates/SFT

{
 "Console URL": "https://us-east-1.console.aws.amazon.com/sagemaker/home?region=us-
east-1#/cluster-management/<your-cluster-name>"
}
```

Jobstatus wird überprüft

Überwachen Sie Ihre laufenden Jobs mit kubectl:

```
kubectl get pods -o wide -w -n kubeflow | (head -n1 ; grep <your-job-name>)
```

## Pod-Status verstehen

In der folgenden Tabelle werden die häufigsten Pod-Status erklärt:

| Status                          | Description                                                                                                                   |
|---------------------------------|-------------------------------------------------------------------------------------------------------------------------------|
| Pending                         | Der Pod wurde akzeptiert, aber noch nicht für einen Knoten geplant oder wartet darauf, dass Container-Images abgerufen werden |
| Running                         | Pod, der an einen Knoten gebunden ist, auf dem mindestens ein Container läuft oder gestartet wird                             |
| Succeeded                       | Alle Container wurden erfolgreich abgeschlossen und werden nicht neu gestartet                                                |
| Failed                          | Alle Container wurden beendet, wobei mindestens einer mit einem Fehler endete                                                 |
| Unknown                         | Der Pod-Status kann nicht bestimmt werden (normalerweise aufgrund von Problemen mit der Knotenkommunikation)                  |
| CrashLoopBackOff                | Container schlägt wiederholt fehl; Kubernetes zieht sich von Neustartversuchen zurück                                         |
| ImagePullBackOff / ErrImagePull | Das Container-Image konnte nicht aus der Registrierung abgerufen werden                                                       |
| OOMKilled                       | Der Container wurde wegen Überschreitung der Speichergrenzen beendet                                                          |
| Completed                       | Job oder Pod erfolgreich abgeschlossen (Batch-Job-Abschluss)                                                                  |

**i** Tip

Verwenden Sie die `-w` Flagge, um sich die Aktualisierungen des Pod-Status in Echtzeit anzusehen. Drücken Sie `Ctrl+C`, um die Wiedergabe zu beenden.

## Jobprotokolle überwachen

Sie können Ihre Protokolle auf drei Arten anzeigen:

### Verwenden CloudWatch

Ihre Protokolle sind in Ihrem AWS Konto verfügbar, das den Hyperpodcluster unter enthält. CloudWatch Um sie in Ihrem Browser anzuzeigen, navigieren Sie in Ihrem Konto zur CloudWatch Startseite und suchen Sie nach Ihrem Clusternamen. Wenn Ihr Cluster beispielsweise aufgerufen würde, hätte `my-hyperpod-rig` die Protokollgruppe das Präfix:

- Protokollgruppe: `/aws/sagemaker/Clusters/my-hyperpod-rig/{UUID}`
- Sobald Sie in der Protokollgruppe sind, können Sie Ihr spezifisches Protokoll anhand der Knoteninstanz-ID wie `-i-00b3d8a1bf25714e4` finden.
  - `i-00b3d8a1bf25714e4` steht hier für den Hyperpod-freundlichen Computernamen, auf dem Ihr Trainingsjob ausgeführt wird. Erinnern Sie sich, wie wir in der vorherigen **`kubectl get pods -o wide -w -n kubeflow | (head -n1 ; grep my-cpt-run)`** Befehlsausgabe eine Spalte namens `NODE` erfasst haben.
  - Der „Master“-Knoten wurde in diesem Fall auf Hyperpod `i-00b3d8a1bf25714e4` - ausgeführt. Daher verwenden wir diese Zeichenfolge, um die anzuzeigende Protokollgruppe auszuwählen. Wählen Sie den aus, der sagt `SageMakerHyperPodTrainingJob/rig-group/[NODE]`

### CloudWatch Insights verwenden

Wenn Sie Ihren Jobnamen griffbereit haben und nicht alle oben genannten Schritte durchführen möchten, können Sie einfach alle Logs unter abfragen, `/aws/sagemaker/Clusters/my-hyperpod-rig/{UUID}` um das individuelle Protokoll zu finden.

CPT:

```
fields @timestamp, @message, @logStream, @log
| filter @message like /(?!Starting CPT Job/
```

```
| sort @timestamp desc
| limit 100
```

Um den Auftrag abzuschließen, ersetzen Sie ihn durch `Starting CPT Job CPT Job completed`

Dann können Sie sich durch die Ergebnisse klicken und diejenige mit der Aufschrift „Epoche 0“ auswählen, da dies Ihr Masternode sein wird.

## Verwendung der AWS CLI

Sie können sich dafür entscheiden, Ihre Logs mit dem zu verfolgen. AWS CLI Bevor Sie dies tun, überprüfen Sie bitte Ihre AWS CLI Version mit `aws --version`. Es wird auch empfohlen, dieses Utility-Skript zu verwenden, das bei der Live-Protokollverfolgung in Ihrem Terminal hilft

für V1:

```
aws logs get-log-events \
--log-group-name /aws/sagemaker/YourLogGroupName \
--log-stream-name YourLogStream \
--start-from-head | jq -r '.events[].message'
```

für V2:

```
aws logs tail /aws/sagemaker/YourLogGroupName \
--log-stream-name YourLogStream \
--since 10m \
--follow
```

## Aktive Jobs auflisten

Alle Jobs anzeigen, die in Ihrem Cluster ausgeführt werden:

```
hyperpod list-jobs -n kubeflow
```

Beispielausgabe:

```
{
 "jobs": [
 {
 "Name": "test-run-nhgza",
 "Namespace": "kubeflow",
 "CreationTime": "2025-10-29T16:50:57Z",
```

```
 "State": "Running"
 }
]
}
```

## Stornieren eines Auftrags

Stoppen Sie einen laufenden Job jederzeit:

```
hyperpod cancel-job --job-name <job-name> -n kubeflow
```

Finden Sie Ihren Jobnamen

Option 1: Aus deinem Rezept

Der Jobname ist im run Block Ihres Rezepts angegeben:

```
run:
 name: "my-test-run" # This is your job name
 model_type: "amazon.nova-micro-v1:0:128k"
 ...
```

Option 2: Aus dem Befehl list-jobs

Verwenden `hyperpod list-jobs -n kubeflow` und kopieren Sie das Name Feld aus der Ausgabe.

## Einen Evaluierungsjob ausführen

Evaluieren Sie ein trainiertes Modell oder Basismodell anhand eines Bewertungsrezepts.

Voraussetzungen

Bevor Sie Evaluierungsjobs ausführen, stellen Sie sicher, dass Sie über Folgendes verfügen:

- Checkpoint Amazon S3 S3-URI aus der `manifest.json` Datei Ihres Trainingsjobs (für trainierte Modelle)
- Bewertungsdatensatz wurde im richtigen Format auf Amazon S3 hochgeladen
- Amazon S3-Pfad für Evaluierungsergebnisse ausgeben

Befehl

Führen Sie den folgenden Befehl aus, um einen Evaluierungsjob zu starten:

```
hyperpod start-job -n kubeflow \
 --recipe evaluation/nova/nova_2_0/nova_lite/
nova_lite_2_0_p5_48xl_gpu_bring_your_own_dataset_eval \
 --override-parameters '{
 "instance_type": "p5.48xlarge",
 "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-
HP-Eval-latest",
 "recipes.run.name": "<your-eval-job-name>",
 "recipes.run.model_name_or_path": "<checkpoint-s3-uri>",
 "recipes.run.output_s3_path": "s3://<your-bucket>/eval-results/",
 "recipes.run.data_s3_path": "s3://<your-bucket>/eval-data.jsonl"
 }'
```

Beschreibungen der Parameter:

- `recipes.run.name`: Eindeutiger Name für Ihren Bewertungsjob
- `recipes.run.model_name_or_path`: Amazon S3 S3-URI von `manifest.json` oder Basismodellpfad (z. B. `nova-micro/prod`)
- `recipes.run.output_s3_path`: Amazon S3 S3-Standort für Evaluierungsergebnisse
- `recipes.run.data_s3_path`: Amazon S3 S3-Speicherort Ihres Bewertungsdatensatzes

Tipps:

- Model-specific Rezepte: Jede Modellgröße (Micro, Lite, Pro) hat ihr eigenes Bewertungsrezept
- Bewertung des Basismodells: Verwenden Sie Basismodellpfade (z. B. `nova-micro/prod`) anstelle von Checkpoint-URIs, um Basismodelle zu bewerten

Format der Bewertungsdaten

Eingabeformat (JSONL):

```
{
 "metadata": "{key:4, category:'apple'}",
 "system": "arithmetic-patterns, please answer the following with no other words: ",
 "query": "What is the next number in this series? 1, 2, 4, 8, 16, ?",
 "response": "32"
}
```

## Ausgabeformat:

```
{
 "prompt": "[{'role': 'system', 'content': 'arithmetic-patterns, please answer the following with no other words: '}, {'role': 'user', 'content': 'What is the next number in this series? 1, 2, 4, 8, 16, ?'}]",
 "inference": "['32']",
 "gold": "32",
 "metadata": "{key:4, category:'apple'}"
}
```

## Feldbeschreibungen:

- **prompt:** Formatierte Eingabe, die an das Modell gesendet wurde
- **inference:** Die generierte Antwort des Modells
- **gold:** Richtige Antwort aus dem Eingabedatensatz erwartet
- **metadata:** Optionale Metadaten, die von der Eingabe übergeben wurden

## Häufige Probleme

- **ModuleNotFoundError: No module named 'nemo\_launcher'**, je nachdem, wo es installiert `hyperpod_cli` ist `nemo_launcher`, müssen Sie möglicherweise zu Ihrem Python-Pfad etwas hinzufügen. Beispielbefehl:

```
export PYTHONPATH=<path_to_hyperpod_cli>/sagemaker-hyperpod-cli/src/hyperpod_cli/
sagemaker_hyperpod_recipes/launcher/nemo/nemo_framework_launcher/launcher_scripts:
$PYTHONPATH
```

- **FileNotFoundError: [Errno 2] No such file or directory: '/tmp/hyperpod\_current\_context.json'** weist darauf hin, dass Sie den Befehl `hyperpod connect cluster` nicht ausgeführt haben.
- Wenn Ihr Job nicht geplant ist, überprüfen Sie noch einmal, ob die Ausgabe Ihrer SageMaker HyperPod CLI diesen Abschnitt mit Jobnamen und anderen Metadaten enthält. Wenn nicht, installieren Sie `helm chart` erneut, indem Sie Folgendes ausführen:

```
curl -fsSL -o get_helm.sh https://raw.githubusercontent.com/helm/helm/main/scripts/
get-helm-3
chmod 700 get_helm.sh
./get_helm.sh
```



```
rm -f ./get_helm.sh
```

## Zugang und Einrichtung von Nova Forge für

Um Amazon Nova Forge für die Verwendung mit Jobs einzurichten, müssen Sie:

- Abonnieren Sie Amazon Nova Forge
- Richten Sie einen Cluster ein

### Themen

- [Abonnieren Sie Amazon Nova Forge](#)
- [Infrastruktur einrichten](#)
- [Verantwortungsvolle KI](#)

## Abonnieren Sie Amazon Nova Forge

Gehen Sie wie folgt vor, um auf die Funktionen von Amazon Nova Forge zuzugreifen:

1. Überprüfen Sie den Administratorzugriff auf das AWS Konto.
2. Navigieren Sie zur SageMaker KI-Konsole und [fordern Sie Zugriff auf Amazon Nova Forge](#) an.
3. Warten Sie, bis das Amazon Nova-Team eine Bestätigung per E-Mail erhalten hat, nachdem die Abonnementanfrage genehmigt wurde.
4. Kennzeichnen Sie Ihre Ausführungsrolle mit dem `forge-subscription` Tag. Dieses Tag ist für den Zugriff auf Funktionen und Checkpoints von Amazon Nova Forge erforderlich. Fügen Sie Ihrer Ausführungsrolle das folgende Tag hinzu:
  - Schlüssel: `forge-subscription`
  - Wert: `true`

### Note

Die Standardfunktionen von Amazon Nova bleiben auch ohne ein Forge-Abonnement verfügbar. Amazon Nova Forge wurde für die Erstellung maßgeschneiderter Frontier-Modelle mit Kontrolle und Flexibilität in allen Modelltrainingsphasen entwickelt.

## Infrastruktur einrichten

Sobald Ihr Amazon Nova Forge-Abonnement genehmigt wurde, richten Sie die erforderliche Infrastruktur für die Nutzung der Forge-enabled Funktionen ein. Ausführliche Anweisungen zur Erstellung eines EKS-Clusters mit einer eingeschränkten Instanzgruppe (RIG) finden Sie in den [Workshop-Anweisungen](#).

## Verantwortungsvolle KI

Einstellungen für die Inhaltsmoderation: Kunden von Amazon Nova Forge haben Zugriff auf anpassbare Inhaltsmoderationseinstellungen (CCMS) für die Modelle Amazon Nova Lite 1.0 und Pro 1.0. Mit CCMS können Sie die Steuerung der Inhaltsmoderation an Ihre spezifischen Geschäftsanforderungen anpassen und gleichzeitig wichtige verantwortungsvolle KI-Sicherheitsvorkehrungen einhalten. Um festzustellen, ob Ihr geschäftlicher Anwendungsfall für CCMS in Frage kommt, wenden Sie sich an Ihren Amazon Web Services Services-Kundenbetreuer.

Amazon Nova Forge bietet ein Toolkit für verantwortungsvolle KI, das Trainingsdaten, Bewertungsbenchmarks und Laufzeitkontrollen umfasst, damit Sie Ihre Modelle an die Richtlinien für verantwortungsvolle KI von Amazon Nova anpassen können.

Trainingsdaten: Die Kategorie „RAI“ bei der Datenmischung umfasst Fälle und Szenarien, in denen verantwortungsvolle KI-Prinzipien, Sicherheitsüberlegungen und verantwortungsvoller Technologieeinsatz im Vordergrund stehen. Verwenden Sie diese, um Ihre Modelle während der weiteren Vorschulung verantwortungsbewusst aufeinander abzustimmen.

Bewertungen: Es stehen Benchmark-Aufgaben zur Verfügung, mit denen Sie die Fähigkeit Ihres Modells testen können, unangemessene, schädliche oder falsche Inhalte zu erkennen und abzulehnen. Verwenden Sie diese Bewertungen, um den Unterschied zwischen der Leistung des Basismodells und der Leistung Ihres benutzerdefinierten Modells zu messen.

## Schulung für Amazon Nova-Modelle

Das Training von Amazon Nova-Modellen auf SageMaker HyperPod unterstützt mehrere Techniken, darunter Continued Pre-Training (CPT), Supervised Fine-Tuning (SFT) und Reinforcement Fine-Tuning (RFT). Jede Technik erfüllt unterschiedliche Anpassungsanforderungen und kann auf verschiedene Amazon Nova-Modellversionen angewendet werden.

### Themen

- [Fortgesetztes Vortraining \(CPT\)](#)

- [Überwachte Optimierung \(SFT\)](#)
- [Reinforcement Fine-Tuning \(RFT\) aktiviert SageMaker HyperPod](#)

## Fortgesetztes Vortraining (CPT)

Continued Pre-Training (CPT) ist eine Trainingstechnik, die die Vortrainingsphase eines Basismodells verlängert, indem es mit zusätzlichem unbeschriftetem Text aus bestimmten Bereichen oder Korpora vertraut gemacht wird. Im Gegensatz zur überwachten Feinabstimmung, für die beschriftete Input-Output-Paare erforderlich sind, trainiert CPT anhand von Rohdokumenten, um dem Modell zu helfen, sich tiefere Kenntnisse über neue Bereiche anzueignen, domänenspezifische Terminologie und Schreibmuster zu erlernen und sich an bestimmte Inhaltstypen oder Fachbereiche anzupassen.

Dieser Ansatz ist besonders nützlich, wenn Sie über große Mengen (zig Milliarden Tokens) domänenspezifischer Textdaten verfügen, wie z. B. Rechtsdokumente, medizinische Literatur, technische Dokumentation oder firmeneigene Geschäftsinhalte, und Sie möchten, dass das Modell in diesem Bereich systemeigene Sprachkenntnisse entwickelt. Im Allgemeinen muss das Modell nach der CPT-Phase weitere Stufen zur Anpassung der Anweisungen durchlaufen, damit das Modell das neu gewonnene Wissen nutzen und nützliche Aufgaben ausführen kann.

### Unterstützte Modelle

CPT ist für die folgenden Amazon Nova-Modelle verfügbar:

- Nova 1.0 (Micro, Lite, Pro)
- Nova 2.0 (Lite)

Wann sollte Nova 1.0 im Vergleich zu Nova 2.0 verwendet werden

Die Amazon Nova-Modellfamilie bietet mehrere Preis-Leistungs-Betriebspunkte, um ein optimales Verhältnis zwischen Genauigkeit, Geschwindigkeit und Kosten zu erzielen.

Wählen Sie Nova 2.0, wenn Sie Folgendes benötigen:

- Fortgeschrittene Argumentationsfähigkeiten für komplexe analytische Aufgaben
- Überragende Leistung in den Bereichen Programmieren, Mathematik und wissenschaftliche Problemlösung
- Unterstützung für längere Kontextlängen
- Bessere mehrsprachige Leistung

**Note**

Das größere Modell ist nicht immer besser. Berücksichtigen Sie bei der Auswahl zwischen den Modellen Nova 1.0 und Nova 2.0 den Kosten-Nutzen-Kompromiss und Ihre spezifischen Geschäftsanforderungen.

**CPT auf Nova 2.0**

Amazon Nova Lite 2.0 ist ein Argumentationsmodell, das auf größeren und vielfältigeren Datensätzen als Nova Lite 1.0 trainiert wurde. Obwohl es sich um ein größeres Modell handelt, bietet Nova Lite 2.0 schnellere Schlussfolgerungen als Nova Lite 1.0 und bietet gleichzeitig erweiterte Argumentationsfähigkeiten, längere Kontextlängen und eine verbesserte Leistung bei Mehrsprachigkeit.

CPT auf Nova 2.0 ermöglicht es Ihnen, diese erweiterten Funktionen mit Ihren domänenspezifischen Daten zu erweitern, sodass das Modell fundierte Fachkenntnisse in Spezialgebieten entwickeln und gleichzeitig seine überlegenen Argumentations- und Analysefähigkeiten beibehalten kann.

**Beispiel für ein CPT-Rezept**

Im Folgenden finden Sie ein Beispielrezept für CPT. Sie finden dieses und andere [Rezepte](#) im [Rezepte-Repository](#).

```
Note:
This recipe can run on p5.48xlarge
Run config
run:
 name: "my-cpt-run" # A descriptive name for your training
 job
 model_type: "amazon.nova-2-lite-v1:0:256k" # Model variant specification, do not
 change
 model_name_or_path: "nova-lite-2/prod" # Base model path, do not change
 replicas: 8 # Number of compute instances for
 training, allowed values are 4, 8, 16, 32
 data_s3_path: "" # Customer data paths
 validation_data_s3_path: "" # Customer validation data paths
 output_s3_path: "" # Output artifact path, job-specific
 configuration - not compatible with standard SageMaker Training Jobs
 mlflow_tracking_uri: "" # Required for MLFlow
 mlflow_experiment_name: "my-cpt-experiment" # Optional for MLFlow. Note: leave this
 field non-empty
```

```

mlflow_run_name: "my-cpt-run" # Optional for MLFlow. Note: leave this
field non-empty

Training specific configs
training_config:
 task_type: cpt
 max_length: 8192 # Maximum context window size (tokens)
 global_batch_size: 256 # Global batch size, allowed values are
32, 64, 128, 256.

 trainer:
 max_steps: 10 # The number of training steps to run
total
 val_check_interval: 10 # The number of steps between running
validation. Integer count or float percentage
 limit_val_batches: 2 # Batches of the validation set to use
each trigger

 model:
 hidden_dropout: 0.0 # Dropout for hidden states, must be
between 0.0 and 1.0
 attention_dropout: 0.0 # Dropout for attention weights, must
be between 0.0 and 1.0

 optim:
 optimizer: adam
 lr: 1e-5 # Learning rate
 name: distributed_fused_adam # Optimizer algorithm, do not change
 adam_w_mode: true # Enable AdamW mode
 eps: 1e-06 # Epsilon for numerical stability
 weight_decay: 0.0 # L2 regularization strength, must be
between 0.0 and 1.0
 adam_beta1: 0.9 # Beta1 for Adam optimizer
 adam_beta2: 0.95 # Beta2 for Adam optimizer
 sched:
 warmup_steps: 10 # Learning rate warmup steps
 constant_steps: 0 # Steps at constant learning rate
 min_lr: 1e-6 # Minimum learning rate, must be lower
than lr

```

## Datenaufbereitung für CPT auf 2.0

### Datenformatanforderungen

Bei den Trainings- und Validierungsdatensätzen muss es sich um JSONL-Dateien im unten angegebenen Format handeln, wobei jede Zeile ein JSON-Objekt enthält, das eine Konversation mit den erforderlichen Feldern und der erforderlichen Struktur darstellt. Ein Beispiel:

```
{"text": "AWS stands for Amazon Web Services"}
{"text": "Amazon SageMaker is a fully managed machine learning service"}
{"text": "Amazon Bedrock is a fully managed service for foundation models"}
```

Texteinträge sollten natürlich fließende, qualitativ hochwertige Inhalte enthalten, die die Zieldomäne repräsentieren.

Testen Sie, ob die Daten in das [Arrow-Format](#) konvertiert werden können. Verwenden Sie das folgende Python-Skript, um Ihnen dabei zu helfen. Stellen Sie sicher, dass mindestens die `datasets==2.18.0` Version verwendet wird:

```
from datasets import load_dataset, load_from_disk
from pathlib import Path

input_path = Path("<Your jsonl file>")
output_path = Path("<Your output directory>")

dataset = load_dataset("json", data_files=str(input_path), split="train")
dataset.save_to_disk(str(output_path), max_shard_size="1GB")

try:
 test_dataset = datasets.load_from_disk(output_dir)
 print(f"Dataset loaded successfully #! Contains {len(test_dataset)} samples")
except Exception as e:
 print(e)
```

Es sollte dieselbe Anzahl von Zeilen drucken wie in der JSONL-Datei.

Wenn Sie Datamixing verwenden, führen Sie den ersten Job mit `aus. max_steps=2` aus. Dies hilft dabei, Optimierungen im Cluster für den Datenzugriff vorzunehmen und zu überprüfen, ob alle Datamixe verfügbar sind.

Wie bereitet man Daten für CPT vor

Trainingsdaten sind der wichtigste entscheidende Faktor für den Erfolg eines kontinuierlichen Vortrainings. CPT-Daten werden zwar oft als „unbeschriftet“ beschrieben, die Realität ist jedoch

weitaus nuancierter. Wie Daten strukturiert, formatiert und präsentiert werden, bestimmt, ob das Modell die für den Geschäftsanwendungsfall erforderlichen Kenntnisse und Fähigkeiten vermittelt.

### Vorbereitung strukturierter Geschäftsdatensätze für CPT

Dies ist eine häufige Herausforderung für Unternehmen und Organisationen, die auf ihren Bereich spezialisierte Basismodelle entwickeln. Die meisten Unternehmen verfügen über umfangreiche Repositorien strukturierter Daten: Produktkataloge, Benutzerprofile, Transaktionsprotokolle, Formulareinreichungen, API-Aufrufe und Betriebsmetadaten. Auf den ersten Blick sieht dieser Text ganz anders aus als der unstrukturierte Webtext, der normalerweise in Standardvorschulungen verwendet wird.

Um effektiv aus strukturierten Geschäftsdaten zu lernen, sollten Sie sorgfältig über nachgelagerte Aufgaben nachdenken und die Datendarstellung so gestalten, dass das Modell die richtigen prädiktiven Beziehungen lernt.

Um das volle Potenzial kontinuierlicher Vorschulungen auszuschöpfen, sollten Sie Folgendes in Betracht ziehen:

- Welche Aufgaben sollte das Modell zur Zeit der Inferenz erfüllen
- Welche Informationen sind in den Rohdaten enthalten
- Wie strukturiert man diese Daten, damit das Modell lernt, die Informationen korrekt zu extrahieren und zu bearbeiten

Strukturierte Daten einfach in das Training zu übertragen, bringt dem Modell nicht bei, darüber nachzudenken. Gestalten Sie die Datendarstellung aktiv so, dass das Modell daraus lernt.

In den folgenden Abschnitten finden Sie eine Literaturübersicht, die die Bedeutung der Datenerweiterung aufzeigt, und es werden Beispiele für Strategien zur Erweiterung strukturierter Geschäftsdaten vorgestellt, die nützliche Anregungen zur Behandlung und Organisation von Unternehmensdatensätzen für CPT geben.

### Strukturierte Daten für CPT in der Literatur

CPT kann zwar Domänenfakten in das Modell packen, schafft es jedoch häufig nicht, diese Fakten abrufbar und manipulierbar zu machen, wenn sich Eingaben oder Aufgaben verschieben. Kontrollierte Experimente zeigen, dass sich Modelle ohne vielfältige Erweiterung während des Vortrainings Fakten auf spröde Weise merken, die auch nach einer späteren Anpassung der Anweisungen schwer zu extrahieren sind, und sie empfehlen, instruktionsähnliche Signale zu Beginn

des Trainings zu injizieren. Bei halbstrukturierten Daten reduzieren randomisierte Serialisierung und andere Erweiterungen die Überanpassung von Schemas. Aus diesem Grund sollte CPT mit Aufgaben im Befehlsstil verschachtelt werden, anstatt zuerst ausgeführt und dann IFT. Untersuchungen, die sich auf das Finanzwesen konzentrieren, haben außerdem ergeben, dass das gemeinsame Mischen von CPT- und Befehlsdaten während der Batchzeit die Generalisierung verbessert und das Vergessen im Vergleich zur sequentiellen Rezeptur reduziert. Der technische Bericht von Qwen folgt demselben Muster, indem hochwertige Unterrichtsdaten in die Vorschulung selbst integriert werden, wodurch das Lernen im Kontext gefördert wird und die Einhaltung der Anweisungen erhalten bleibt, während gleichzeitig neues Fachwissen erworben wird.

Die Erweiterung der Daten für halbstrukturierte Korpora ist ein wichtiger Hebel. CPT, das synthetische Graphen berücksichtigt, erweitert kleine Domänensätze zu Entitätsverknüpften Korpora, die explizit Beziehungen und Verbindungen vermitteln, wobei der Abruf zum Zeitpunkt der Inferenz erfolgt. Gemeinsames CPT in Kombination mit Instruktionsmischung übertrifft sequentielle Pipelines im Finanzwesen und die Bilanzierung allgemeiner Daten verringert den Abbau allgemeiner Fähigkeiten. CPT in sehr großem Maßstab kann auch weiterhin breit gefächerte Fähigkeiten beibehalten und sogar Kompromisse durch die Zusammenführung von Modellen ermöglichen, weist aber dennoch darauf hin, dass die Anpassung der Lehrpläne ein wesentlicher nächster Schritt ist, wodurch der Wert der Einführung von Unterrichtssignalen während der CPT verstärkt wird.

### Schaffung von Diversität durch Randomisierung und Mischen

Eine allgemeine Strategie, die hilft, anhand strukturierter und halbstrukturierter Datensätze effektiv Modelle zu vermitteln, besteht darin, die Reihenfolge der Felder in den Datensätzen zu mischen und einige Schlüssel sogar nach dem Zufallsprinzip wegzulassen.

Das Mischen der Felder zwingt das Modell dazu, zu lesen, was jeder Wert bedeutet, anstatt zu wissen, wo er erscheint, und die Beziehungen zwischen allen Feldern zu lernen. Wenn beispielsweise bei einem Videospiel, das im Amazon Store veröffentlicht wird, „Titel“, „Plattform“, „Preis“, „Zustand“ und „Ausgabe“ in unterschiedlichen Permutationen erscheinen, kann sich das Modell nicht auf „der dritte Slot ist Plattform“ verlassen. Es muss Labels an Werte binden und die bilateralen Beziehungen zwischen den Attributen lernen: Titel  $\rightleftharpoons$  Plattform, Plattform  $\rightleftharpoons$  Preis, Zustand  $\rightleftharpoons$  Preis. So kann es beispielsweise anhand eines Spielnamens und eines beobachteten Preises auf eine wahrscheinliche Plattform schließen oder eine plausible Preisspanne für einen Titel und eine Plattform abschätzen.

Das zufällige Ablegen von Schlüsseln während der Serialisierung wirkt wie ein Feature-Dropout: Es verhindert die Koadaption in einem Feld und zwingt das Modell, fehlende Informationen aus den verbleibenden Beweisen wiederherzustellen. Fehlt „Plattform“, muss das Modell es aus der



Titelzeichenfolge oder dem Kompatibilitätstext übernehmen. Wenn „Price“ ausgeblendet ist, muss es eine Triangulierung nach Plattform, Edition und Zustand vornehmen. Dies sorgt für Symmetrie ( $A \rightarrow B$  und  $B \rightarrow A$ ), Stabilität gegenüber unübersichtlichen Auflistungen in der realen Welt und Schemainvarianz, wenn Felder fehlen, umbenannt oder neu angeordnet werden.

Ein Beispiel im Einkaufsstil macht es konkret. Serialisieren Sie denselben Artikel auf mehrere Arten — „Titel: 'Elden Ring' | Plattform: PlayStation 5 | Zustand: Gebraucht—Wie neu | Preis: 34,99\$“ und eine Permutation wie „Preis: 34,99\$ | Titel: 'Elden Ring' | Zustand: Gebraucht—wie neu | Plattform: 5“ — und bei einigen Durchgängen lassen Sie „Plattform“ weg, während „Kompatibel mit“ in der Beschreibung belassen wird. PlayStation PS5 Trainiere ergänzende Ziele wie die Vorhersage der Plattform anhand von {title, price} und die Vorhersage eines Preisbereichs anhand von {title, platform}. Da die Reihenfolge und sogar das Vorhandensein von Schlüsseln variieren, besteht die einzig stabile Strategie darin, die wahren Beziehungen zwischen Attributen zu lernen, anstatt sich eine Vorlage zu merken.

Die Art und Weise, wie Daten präsentiert werden, ist wichtig

LLMs lernen Sie, indem Sie anhand dessen, was sie bereits gesehen haben, das nächste Token vorhersagen. Die Reihenfolge der Felder und Ereignisse, die während des Trainings angezeigt werden, entscheidet also darüber, was das Modell lernen kann. Wenn das Trainingsformat mit der tatsächlichen Aufgabe übereinstimmt, wird der Verlust genau auf die Entscheidungstoken zurückgeführt. Werden Felder ohne Struktur zusammengewürfelt, lernt das Modell Abkürzungen oder merkt sich Beliebtheit und scheitert dann, wenn es aufgefordert wird, zwischen Optionen zu wählen.

Zeigen Sie zuerst die Situation, dann die Optionen und dann die Entscheidung. Wenn das Modell auch Informationen zu Ergebnissen oder Erklärungen erhalten soll, fügen Sie diese nach der Entscheidung ein.

Proben für CPT verpacken

Was ist Verpacken?

Es bedeutet einfach, jedes Sequenzfenster in den Trainingsdaten mit mehreren ganzen Beispielen zu füllen, sodass das Fenster dicht mit echten Tokens und nicht mit Füllungen ist.

Warum dies wichtig ist

Während des Trainings wird eine maximale Kontextlänge festgelegt, zum Beispiel 8.192 Token. Stapel werden auf [Stapelgröße × Kontextlänge] geformt. Wenn ein Trainingsbeispiel kürzer als die Länge des Kontextes ist, werden die verbleibenden Positionen aufgefüllt. Auch wenn der Verlust

maskiert wird, werden die Aufmerksamkeits- und MLP-Kernel immer noch mit dem Auffüllen gefüllt, sodass die Rechenleistung für Tokens, die kein Lernsignal enthalten, bezahlt wird.

Wie packt man?

Um mehrere Proben zu packen, verketteten Sie mehrere Trainingsproben mit einem [DOC] Trennzeichen dazwischen (beachten Sie das Leerzeichen vor und nach dem [DOC]), sodass die gesamte Länge der Proben unter der gewünschten Kontextlänge liegt.

Ein Beispiel für ein gepacktes Dokument würde wie folgt aussehen:

```
{"text": "training sample 1 [DOC] training sample 2 [DOC] training sample 3"}
```

## CPT-Tuning-Parameter

Zu den Parametern, die für die Feinabstimmung mit CPT verfügbar sind, gehören:

### Ausführen der Konfiguration

- **Name:** Ein aussagekräftiger Name für Ihren Ausbildungsjob. Auf diese Weise können Sie Ihren Job in der AWS Management Console leichter identifizieren.
- **model\_type:** Die zu verwendende Amazon Nova-Modellvariante. Die verfügbaren Optionen sind. `amazon.nova-2-lite-v1:0:256k`
- **model\_name\_or\_path:** Der Pfad zum Basismodell, das Sie für Ihr Training verwenden möchten. Die verfügbaren Optionen sind `nova-lite-2/prod`, oder der S3-Pfad für den Checkpoint nach dem Training (). `s3://customer-escrow-bucket-unique_id/training_run_name`
- **Replikate:** Die Anzahl der Recheninstanzen, die für verteilte Schulungen verwendet werden sollen. Die verfügbaren Werte variieren abhängig vom ausgewählten Modell. Amazon Nova Lite 2.0 unterstützt 4, 8, 16 oder 32 Replikate.
- **data\_s3\_path:** Der S3-Speicherort des Trainingsdatensatzes, bei dem es sich um eine JSONL-Datei handelt. Diese Datei muss sich in demselben Konto und derselben Region wie AWS der Cluster befinden. Alle angegebenen S3-Standorte müssen sich im selben Konto und in derselben Region befinden.
- **validation\_data\_s3\_path:** (Optional) Der S3-Speicherort des Validierungsdatensatzes, bei dem es sich um eine JSONL-Datei handelt. Diese Datei muss sich im selben Konto und derselben Region wie der Cluster befinden. Alle angegebenen S3-Standorte müssen sich im selben Konto und in derselben Region befinden.

- `output_s3_path`: Der S3-Speicherort, an dem das Manifest und die Protokolle gespeichert werden. TensorBoard Alle angegebenen S3-Standorte müssen sich im selben Konto und in derselben AWS Region befinden. AWS
- `mlflow_tracking_uri`: Der ARN der App, der für die Protokollierung verwendet werden soll MLFlow MLFlow
- MLFlow `mlflow_experiment_name`: Name des Experiments
- `mlflow_run_name`: MLFlow Laufname

## Konfiguration des Trainings

- `max_length`: Die maximale Sequenzlänge in Tokens. Dies bestimmt die Größe des Kontextfensters für das Training. Der maximal unterstützte Wert beträgt 8192 Token für CPT.

Längere Sequenzen verbessern die Trainingseffizienz auf Kosten eines erhöhten Speicherbedarfs. Wir empfehlen, dass Sie den Parameter `max_length` an Ihre Datenverteilung anpassen.

- `global_batch_size`: Die Gesamtzahl der Trainingsproben, die zusammen in einem Vorwärts- oder Rückwärtsgang für alle Geräte und Mitarbeiter verarbeitet wurden.

Dieser Wert multipliziert die Batchgröße pro Gerät und die Anzahl der Geräte. Er wirkt sich auf die Stabilität des Trainings und den Durchsatz aus. Wir empfehlen Ihnen, mit einer Batchgröße zu beginnen, die problemlos in Ihren Arbeitsspeicher passt, und anschließend hochzuskalieren. Bei Domain-spezifischen Daten können größere Batches zu einer übermäßigen Gradientenglättung führen.

## Trainer-Einstellungen

- `max_steps`: Die Anzahl der auszuführenden Trainingsschritte. Jeder Schritt trainiert das Modell mit der `global_batch_size` Anzahl der Elemente

## Einstellungen des Modells

- `hidden_dropout`: Die Wahrscheinlichkeit, dass versteckte Statusausgaben gelöscht werden. Erhöhen Sie diesen Wert um etwa 0,0 bis 0,2, um eine Überanpassung bei kleineren Datensätzen zu vermeiden. Zulässig sind alle Werte zwischen 0 und 1, beide inklusive.

- `attention_dropout`: Die Wahrscheinlichkeit, dass die Aufmerksamkeit verloren geht. Dieser Parameter kann bei der Generalisierung helfen. Zulässig sind alle Werte zwischen 0 und 1, beide inklusive.

## Konfiguration des Optimierers

- `lr`: Die Lernrate, die die Schrittgröße während der Optimierung steuert. Für eine gute Leistung empfehlen wir Werte zwischen  $1e-6$  und  $1e-4$ . Zulässig sind alle Werte zwischen 0 und 1, beide inklusive.
- `Name`: Der Optimierer-Algorithmus. Derzeit wird nur `distributed_fused_adam` unterstützt.
- `weight_decay`: Die Stärke der L2-Regularisierung. Höhere Werte (zwischen 0,01 und 0,1) erhöhen die Regularisierung.
- `warmup_steps`: Die Anzahl der Schritte zur schrittweisen Erhöhung der Lernrate. Dies verbessert die Trainingsstabilität. Zulässig sind alle Werte zwischen 1 und 20, beide inklusive.
- `min_lr`: Die minimale Lernrate am Ende des Zerfalls. Gültige Werte liegen zwischen 0 und 1 (beide inklusive), müssen jedoch unter der Lernrate liegen.

## Überwachte Optimierung (SFT)

Der SFT-Trainingsprozess besteht aus zwei Hauptphasen:

- **Datenvorbereitung**: Folgen Sie den festgelegten Richtlinien, um Datensätze zu erstellen, zu bereinigen oder neu zu formatieren, sodass sie die erforderliche Struktur erhalten. Stellen Sie sicher, dass Eingaben, Ausgaben und Zusatzinformationen (wie Argumentationsspuren oder Metadaten) richtig aufeinander abgestimmt und formatiert sind.
- **Trainingskonfiguration**: Definieren Sie, wie das Modell trainiert werden soll. Bei der Verwendung wird diese Konfiguration in eine YAML-Rezeptdatei geschrieben, die Folgendes beinhaltet:
  - Datenquellenpfade (Trainings- und Validierungsdatensätze)
  - Wichtige Hyperparameter (Epochen, Lernrate, Batchgröße)
  - Optionale Komponenten (verteilte Trainingsparameter usw.)

## Vergleich und Auswahl von Nova-Modellen

Amazon Nova 2.0 ist ein Modell, das auf einem größeren und vielfältigeren Datensatz als Amazon Nova 1.0 trainiert wurde. Zu den Verbesserungen gehören:

- Verbesserte Argumentationsfähigkeiten mit Unterstützung für den Modus „Explizites Denken“
- Umfassendere mehrsprachige Leistung in weiteren Sprachen
- Verbesserte Leistung bei komplexen Aufgaben, einschließlich Codierung und Verwendung von Tools
- Erweiterte Kontexthandhabung mit besserer Genauigkeit und Stabilität bei längeren Kontextlängen

Wann sollte Nova 1.0 im Vergleich zu Nova 2.0 verwendet werden

Wählen Sie Amazon Nova 2.0, wenn:

- Überlegene Leistung mit fortgeschrittenen Argumentationsfähigkeiten ist erforderlich
- Mehrsprachiger Support oder die Bearbeitung komplexer Aufgaben sind erforderlich
- Bessere Ergebnisse beim Programmieren, beim Aufrufen von Tools oder bei analytischen Aufgaben sind erforderlich

SFT auf Nova 2.0

Amazon Nova Lite 2.0 bietet erweiterte Funktionen für die überwachte Feinabstimmung, darunter einen erweiterten Argumentationsmodus, ein verbessertes multimodales Verständnis und eine erweiterte Kontexthandhabung. Mit SFT on Nova 2.0 können Sie diese leistungsstarken Funktionen an Ihre spezifischen Anwendungsfälle anpassen und gleichzeitig die überragende Leistung des Modells bei komplexen Aufgaben beibehalten.

Zu den wichtigsten Funktionen von SFT on Nova 2.0 gehören:

- Unterstützung des Argumentationsmodus: Trainieren Sie Modelle so, dass sie vor den endgültigen Antworten explizite Argumentationsspuren erzeugen, um die Analysemöglichkeiten zu verbessern.
- Fortgeschrittenes multimodales Training: Präzise Feinabstimmung in Sachen Dokumentenverständnis (PDF), Videoverständnis und bildgestützte Aufgaben.
- Funktionen zum Aufrufen von Tools: Trainieren Sie Modelle, um externe Tools effektiv zu nutzen und Funktionen für komplexe Workflows aufzurufen.
- Erweiterte Kontextunterstützung: Nutzen Sie längere Kontextfenster mit besserer Stabilität und Genauigkeit für dokumentenintensive Anwendungen.

**Note**

Weitere Informationen darüber, welche Container-Images oder Beispielrezepte verwendet werden sollten, finden Sie unter [Amazon Nova-Rezepte](#).

**Themen**

- [Auswahl des Argumentationsmodus \(nur Nova 2.0\)](#)
- [Datenformat für das Aufrufen des Tools](#)
- [Dokument, das das Datenformat versteht](#)
- [Video Understanding für SFT](#)
- [Anweisungen zum Hochladen von Daten](#)
- [Einen Job zur Feinabstimmung erstellen](#)
- [SFT-Tuning-Parameter](#)
- [Anleitung zu Hyperparametern](#)

**Beispiel für ein SFT-Rezept**

Unten finden Sie ein Beispielrezept für SFT. Sie finden dieses und andere [Rezepte](#) im Rezept-Repository.

```
run:
 name: my-full-rank-sft-run
 model_type: amazon.nova-2-lite-v1:0:256k
 model_name_or_path: nova-lite-2/prod
 data_s3_path: s3://my-bucket-name/train.jsonl # only and not compatible with
SageMaker Training Jobs
 replicas: 4 # Number of compute instances for
training, allowed values are 4, 8, 16, 32
 output_s3_path: s3://my-bucket-name/outputs/ # Output artifact path (HyperPod job-
specific; not compatible with standard SageMaker Training Jobs)
 mlflow_tracking_uri: "" # Required for MLFlow
 mlflow_experiment_name: "my-full-rank-sft-experiment" # Optional for MLFlow. Note:
leave this field non-empty
 mlflow_run_name: "my-full-rank-sft-run" # Optional for MLFlow. Note: leave
this field non-empty
```

```

training_config:
 max_steps: 100 # Maximum training steps. Minimal is 4.
 save_steps: ${oc.select:training_config.max_steps} # How many training steps the
checkpoint will be saved
 save_top_k: 5 # Keep top K best checkpoints. Note supported only
for jobs. Minimal is 1.
 max_length: 32768 # Sequence length (options: 8192, 16384, 32768
[default], 65536)
 global_batch_size: 32 # Global batch size (options: 32, 64, 128)
 reasoning_enabled: true # If data has reasoningContent, set to true;
otherwise False

 lr_scheduler:
 warmup_steps: 15 # Learning rate warmup steps. Recommend 15% of
max_steps
 min_lr: 1e-6 # Minimum learning rate, must be between 0.0 and
1.0

 optim_config: # Optimizer settings
 lr: 1e-5 # Learning rate, must be between 0.0 and 1.0
 weight_decay: 0.0 # L2 regularization strength, must be between 0.0
and 1.0
 adam_beta1: 0.9 # Exponential decay rate for first-moment
estimates
 adam_beta2: 0.95 # Exponential decay rate for second-moment
estimates

 peft: # Parameter-efficient fine-tuning (LoRA)
 peft_scheme: "null" # Disable LoRA for PEFT

```

## Auswahl des Argumentationsmodus (nur Nova 2.0)

Amazon Nova 2.0 unterstützt den Argumentationsmodus für erweiterte Analysefunktionen:

- Argumentationsmodus (aktiviert):
  - `reasoning_enabled: true` in der Trainingskonfiguration festgelegt
  - Modellieren Sie Übungen, um Argumentationsspuren vor den endgültigen Antworten zu generieren
  - Verbessert die Leistung bei komplexen Argumentationsaufgaben
- Modus ohne Argumentation (deaktiviert):
  - Den Parameter setzen `reasoning_enabled: false` oder weglassen (Standard)

- Standard-SFT ohne explizite Begründung
- Geeignet für Aufgaben, bei denen Argumentation nicht von Vorteil ist step-by-step

#### Note

- Wenn Argumentation aktiviert ist, ist ein hoher Argumentationsaufwand erforderlich. Für SFT gibt es keine Option mit geringem Argumentationsaufwand.
- Inhalte zum multimodalen Denken werden für SFT nicht unterstützt. Der Argumentationsmodus gilt für reine Texteingaben.

Verwendung des Argumentationsmodus bei Datensätzen, bei denen es sich nicht um logische Überlegungen handelt

Das Training von Amazon Nova mit einem Datensatz ohne Argumentation `reasoning_enabled: true` ist zulässig. Dies kann jedoch dazu führen, dass das Modell seine Argumentationsfähigkeit verliert, da Amazon Nova in erster Linie lernt, die in den Daten enthaltenen Antworten zu generieren, ohne Argumentation anzuwenden.

Wenn Sie Amazon Nova mit einem Datensatz ohne Argumentation trainieren, aber dennoch Argumentation während der Inferenz verwenden möchten:

1. Deaktivieren Sie die Argumentation während des Trainings () `reasoning_enabled: false`
2. Aktiviere die Argumentation später während der Inferenz

Dieser Ansatz ermöglicht zwar eine Argumentation zum Zeitpunkt der Inferenz, garantiert jedoch keine bessere Leistung im Vergleich zu Schlussfolgerungen ohne Argumentation.

Bewährte Methode: Aktivieren Sie Argumentation sowohl für Training als auch für Folgerungen, wenn Sie Datensätze mit Argumentation verwenden, und deaktivieren Sie sie für beide, wenn Sie Datensätze verwenden, die keine Argumentation verwenden.

#### Note

Weitere Informationen darüber, welche Container-Images oder Beispielrezepte verwendet werden sollten, finden Sie unter [Amazon Nova-Rezepte](#).



## Datenformat für das Aufrufen des Tools

SFT unterstützt Trainingsmodelle für die Verwendung von Tools (Funktionsaufruf). Im Folgenden finden Sie ein Beispiel für ein Eingabeformat für den Aufruf von Tools:

Beispiel für eine Eingabe:

```
{
 "schemaVersion": "bedrock-conversation-2024",
 "system": [
 {
 "text": "You are an expert in composing function calls."
 }
],
 "toolConfig": {
 "tools": [
 {
 "toolSpec": {
 "name": "getItemCost",
 "description": "Retrieve the cost of an item from the catalog",
 "inputSchema": {
 "json": {
 "type": "object",
 "properties": {
 "item_name": {
 "type": "string",
 "description": "The name of the item to retrieve cost for"
 },
 "item_id": {
 "type": "string",
 "description": "The ASIN of item to retrieve cost for"
 }
 }
 },
 "required": [
 "item_id"
]
 }
 }
 },
 {
 "toolSpec": {
 "name": "getItemAvailability",
 "description": "Retrieve whether an item is available in a given location",
```

```

 "inputSchema": {
 "json": {
 "type": "object",
 "properties": {
 "zipcode": {
 "type": "string",
 "description": "The zipcode of the location to check in"
 },
 "quantity": {
 "type": "integer",
 "description": "The number of items to check availability for"
 },
 "item_id": {
 "type": "string",
 "description": "The ASIN of item to check availability for"
 }
 },
 "required": [
 "item_id", "zipcode"
]
 }
 }
],
 "messages": [
 {
 "role": "user",
 "content": [
 {
 "text": "I need to check whether there are twenty pieces of the following item available. Here is the item ASIN on Amazon: id-123. Please check for the zipcode 94086"
 }
]
 },
 {
 "role": "assistant",
 "content": [
 {
 "reasoningContent": {
 "reasoningText": {

```

```

 "text": "The user wants to check how many pieces of the item with ASIN
id-123 are available in the zipcode 94086"
 }
}
},
{
 "toolUse": {
 "toolUseId": "getItemAvailability_0",
 "name": "getItemAvailability",
 "input": {
 "zipcode": "94086",
 "quantity": 20,
 "item_id": "id-123"
 }
 }
}
],
},
{
 "role": "user",
 "content": [
 {
 "toolResult": {
 "toolUseId": "getItemAvailability_0",
 "content": [
 {
 "text": "[{\\"name\\": \\"getItemAvailability\\", \\"results\\":
{\\"availability\\": true}]]"
 }
]
 }
 }
]
},
{
 "role": "assistant",
 "content": [
 {
 "text": "Yes, there are twenty pieces of item id-123 available at 94086.
Would you like to place an order or know the total cost?"
 }
]
}
]

```

```
}
```

### Wichtige Überlegungen zum Aufrufen von Tool-Daten:

- ToolUse darf nur in der Runde des Assistenten erscheinen
- ToolResult darf nur in der Runde eines Benutzers erscheinen
- ToolResult sollte nur Text oder JSON sein; andere Modalitäten werden derzeit für Amazon Nova-Modelle nicht unterstützt
- Das InputSchema in der ToolSpec muss ein gültiges JSON-Schema-Objekt sein
- Jeder Assistent ToolResult muss auf einen gültigen Wert toolUseId aus einem vorherigen Assistenten verweisen ToolUse, wobei jeder Assistent genau einmal pro toolUseId Konversation verwendet wird

#### Note

Weitere Informationen darüber, welche Container-Images oder Beispielrezepte verwendet werden sollten, finden Sie unter [Amazon Nova-Rezepte](#).

### Dokument, das das Datenformat versteht

SFT unterstützt Trainingsmodelle für Aufgaben zum Verständnis von Dokumenten. Im Folgenden finden Sie ein Beispiel für ein Eingabeformat:

### Beispiel für eine Eingabe

```
{
 "schemaVersion": "bedrock-conversation-2024",
 "messages": [
 {
 "role": "user",
 "content": [
 {
 "text": "What are the ways in which a customer can experience issues during checkout on Amazon?"
 },
 {
 "document": {
 "format": "pdf",
```

```
 "source": {
 "s3Location": {
 "uri": "s3://my-bucket-name/path/to/documents/customer_service_debugging.pdf",
 "bucketOwner": "123456789012"
 }
 }
],
 },
 {
 "role": "assistant",
 "content": [
 {
 "text": "Customers can experience issues with 1. Data entry, 2. Payment methods, 3. Connectivity while placing the order. Which one would you like to dive into?"
 }
],
 "reasoning_content": [
 {
 "text": "I need to find the relevant section in the document to answer the question.",
 "type": "text"
 }
]
 }
]
}
```

### Wichtige Überlegungen zum Verständnis von Dokumenten:

- Es werden nur PDF-Dateien unterstützt
- Die maximale Dokumentgröße beträgt 10 MB
- Ein Beispiel kann Dokumente und Text enthalten, darf jedoch keine Kombination von Dokumenten mit anderen Modalitäten (wie Bildern oder Videos) enthalten

 Note

Weitere Informationen darüber, welche Container-Images oder Beispielrezepte verwendet werden sollten, finden Sie unter [Amazon Nova-Rezepte](#).

## Video Understanding für SFT

SFT unterstützt die Feinabstimmung von Modellen für Videoverständnisaufgaben. Im Folgenden finden Sie ein Beispiel für ein Eingabeformat:

### Beispiel für eine Eingabe

```
{
 "schemaVersion": "bedrock-conversation-2024",
 "messages": [
 {
 "role": "user",
 "content": [
 {
 "text": "What are the ways in which a customer can experience issues during checkout on Amazon?"
 },
 {
 "video": {
 "format": "mp4",
 "source": {
 "s3Location": {
 "uri": "s3://my-bucket-name/path/to/videos/customer_service_debugging.mp4",
 "bucketOwner": "123456789012"
 }
 }
 }
 }
]
 },
 {
 "role": "assistant",
 "content": [
 {
```

```

 "text": "Customers can experience issues with 1. Data entry, 2. Payment
methods, 3. Connectivity while placing the order. Which one would you like to dive
into?"
 },
],
 "reasoning_content": [
 {
 "text": "I need to find the relevant section in the video to answer the
question.",
 "type": "text"
 }
]
 }
]
}

```

Wichtige Überlegungen zum Verständnis von Videos:

- Videos können maximal 50 MB groß sein
- Videos können bis zu 15 Minuten lang sein
- Pro Beispiel ist nur ein Video zulässig. Mehrere Videos in derselben Stichprobe werden nicht unterstützt
- Ein Beispiel kann Video und Text enthalten, aber kein Video mit anderen Modalitäten (wie Bildern oder Dokumenten) mischen

#### Note

Weitere Informationen darüber, welche Container-Images oder Beispielrezepte verwendet werden sollten, finden Sie unter [Amazon Nova-Rezepte](#).

## Anweisungen zum Hochladen von Daten

Laden Sie Trainings- und Validierungsdatensätze in einen S3-Bucket hoch. Geben Sie diese Speicherorte im `run` Rezeptblock an:

```

Run config
run:
 ...
 data_s3_path: "s3://<bucket-name>/<training-directory>/<training-file>.jsonl"

```

Hinweis: Ersetzen Sie <bucket-name>, <training-directory>, <validation-directory> <training-file>, und <validation-file> durch tatsächliche S3-Pfade.

Hinweis: Validierungsdatensätze werden derzeit nicht für SFT mit Amazon Nova 2.0 unterstützt. Wenn ein Validierungsdatensatz bereitgestellt wird, wird dieser ignoriert.

Einen Job zur Feinabstimmung erstellen

Definieren Sie das Basismodell mithilfe der `model_name_or_path` Felder `model_type` und im `run` Block:

```
Run config
run:
 ...
 model_type: amazon.nova-2-lite-v1:0:256k
 model_name_or_path: nova-lite-2/prod
 ...
```

SFT-Tuning-Parameter

Zu den Parametern, die für die Optimierung mit SFT verfügbar sind, gehören:

Ausführen der Konfiguration

- **Name:** Ein aussagekräftiger Name für Ihren Ausbildungsjob. Auf diese Weise können Sie Ihren Job in der AWS Management Console leichter identifizieren.
- **model\_type:** Die zu verwendende Amazon Nova-Modellvariante. Die verfügbaren Optionen sind. `amazon.nova-2-lite-v1:0:256k`
- **model\_name\_or\_path:** Der Pfad zum Basismodell, das Sie für Ihr Training verwenden möchten. Die verfügbaren Optionen sind `nova-lite-2/prod`, oder der S3-Pfad für den Checkpoint nach dem Training (). `s3://customer-escrow-bucket-unique_id/training_run_name`
- **Replikate:** Die Anzahl der Recheninstanzen, die für verteilte Schulungen verwendet werden sollen. Die verfügbaren Werte variieren abhängig vom ausgewählten Modell. Amazon Nova Lite 2.0 unterstützt 4, 8, 16 oder 32 Replikate.
- **data\_s3\_path:** Der S3-Speicherort des Trainingsdatensatzes, bei dem es sich um eine JSONL-Datei handelt. Diese Datei muss sich in demselben Konto und derselben Region wie AWS der



Cluster befinden. Alle angegebenen S3-Standorte müssen sich im selben Konto und in derselben Region befinden.

- `validation_data_s3_path`: (Optional) Der S3-Speicherort des Validierungsdatensatzes, bei dem es sich um eine JSONL-Datei handelt. Diese Datei muss sich im selben Konto und derselben Region wie der Cluster befinden. Alle angegebenen S3-Standorte müssen sich im selben Konto und in derselben Region befinden.
- `output_s3_path`: Der S3-Speicherort, an dem das Manifest und die Protokolle gespeichert werden. TensorBoard Alle angegebenen S3-Standorte müssen sich im selben Konto und in derselben AWS Region befinden. AWS
- `mlflow_tracking_uri`: Der ARN der App, der für die Protokollierung verwendet werden soll. MLFlow MLFlow
- `MLFlow mlflow_experiment_name`: Name des Experiments.
- `mlflow_run_name`: Name der Ausführung. MLFlow

## Konfiguration des Trainings

- `max_steps`: Die Anzahl der auszuführenden Trainingsschritte. In jedem Schritt wird das Modell anhand der `global_batch_size` Anzahl der Elemente trainiert.
- `save_steps`: Die Häufigkeit (in Schritten), mit der Modell-Checkpoints während des Trainings gespeichert werden.
- `save_top_k`: Die maximale Anzahl der besten Checkpoints, die auf Grundlage von Validierungsmetriken beibehalten werden sollen.
- `max_length`: Die maximale Sequenzlänge in Token. Dies bestimmt die Größe des Kontextfensters für das Training. Der maximal unterstützte Wert beträgt 32768 Token für SFT.

Längere Sequenzen verbessern die Trainingseffizienz auf Kosten eines erhöhten Speicherbedarfs. Wir empfehlen, dass Sie den Parameter `max_length` an Ihre Datenverteilung anpassen.

- `global_batch_size`: Die Gesamtzahl der Trainingsproben, die zusammen in einem Vorwärts- oder Rückwärtsgang für alle Geräte und Mitarbeiter verarbeitet wurden.

Dieser Wert multipliziert die Batchgröße pro Gerät und die Anzahl der Geräte. Er wirkt sich auf die Stabilität des Trainings und den Durchsatz aus. Wir empfehlen Ihnen, mit einer Batchgröße zu beginnen, die problemlos in Ihren Arbeitsspeicher passt, und anschließend hochzuskalieren. Bei Domain-spezifischen Daten können größere Batches zu einer übermäßigen Gradientenglättung führen.

- `reasoning_enabled`: Boolesches Kennzeichen zur Aktivierung von Argumentationsfähigkeiten während des Trainings.

## Ratenplaner für Lernprogramme

- `warmup_steps`: Die Anzahl der Schritte zur schrittweisen Erhöhung der Lernrate. Dies verbessert die Trainingsstabilität.
- `min_lr`: Die minimale Lernrate am Ende des Zerfalls. Gültige Werte liegen zwischen 0 und 1 (beide inklusive), müssen jedoch unter der Lernrate liegen.

## Konfiguration des Optimierers

- `lr`: Die Lernrate, die die Schrittgröße während der Optimierung steuert. Für eine gute Leistung empfehlen wir Werte zwischen  $1e-6$  und  $1e-4$ . Zulässig sind alle Werte zwischen 0 und 1, beide inklusive.
- `weight_decay`: Die Stärke der L2-Regularisierung. Höhere Werte (zwischen 0,01 und 0,1) erhöhen die Regularisierung.
- `adam_beta1`: Die exponentielle Zerfallsrate für Schätzungen des ersten Moments im Adam-Optimizer. Die Standardeinstellung ist 0,9.
- `adam_beta2`: Die exponentielle Zerfallsrate für Schätzungen des zweiten Moments im Adam-Optimizer. Die Standardeinstellung ist 0,95.

## PEFT-Konfiguration

- `peft_scheme`: Das zu verwendende parametereffiziente Feinabstimmungsschema. Die Optionen stehen für die Feinabstimmung mit vollem Rang oder `'null'` für die Feinabstimmung auf LoRa-Basis zur Verfügung. `lora`

## LoRa-Tuning (wenn `peft_scheme` 'lora' ist)

- `alpha`: Der LoRa-Skalierungsparameter. Steuert das Ausmaß der Low-Rank-Anpassung. Typische Werte liegen im Bereich von 8 bis 128.

- `lora_plus_lr_ratio`: Das Lernratenverhältnis für die LoRa+-Optimierung. Dieser Multiplikator passt die Lernrate speziell für LoRa-Parameter an.

## Anleitung zu Hyperparametern

Verwenden Sie je nach Trainingsansatz die folgenden empfohlenen Hyperparameter:

### Training mit vollem Rang

- Epochen: 1
- Lernrate (`lr`):  $1e-5$
- Minimale Lernrate (`min_lr`):  $1e-6$

### LoRa (Low-Rank-Anpassung)

- Epochen: 2
- Lernrate (`lr`):  $5e-5$
- Minimale Lernrate (`min_lr`):  $1e-6$

Hinweis: Passen Sie diese Werte je nach Datensatzgröße und Validierungsleistung an. Überwachen Sie die Trainingsmetriken, um eine Überanpassung zu vermeiden.

## Reinforcement Fine-Tuning (RFT) aktiviert SageMaker HyperPod

Reinforcement Fine-Tuning (RFT) ist eine Technik des maschinellen Lernens, die die Modellleistung durch Feedbacksignale — messbare Werte oder Belohnungen, die auf die Qualität der Antworten hinweisen — verbessert, anstatt durch direkte Überwachung mit exakt richtigen Antworten. Im Gegensatz zur herkömmlichen überwachten Feinabstimmung, die aus Input-Output-Paaren lernt, verwendet RFT Belohnungsfunktionen, um Modellantworten zu bewerten, und optimiert das Modell iterativ, um diese Belohnungen zu maximieren.

Dieser Ansatz ist besonders effektiv für Aufgaben, bei denen es schwierig ist, die exakte korrekte Ausgabe zu definieren, Sie aber die Qualität der Antworten zuverlässig messen können. RFT ermöglicht es Modellen, komplexe Verhaltensweisen und Präferenzen durch Versuche und Feedback zu erlernen, und eignet sich daher ideal für Anwendungen, die eine nuancierte Entscheidungsfindung, kreative Problemlösung oder die Einhaltung bestimmter Qualitätskriterien erfordern, die programmatisch bewertet werden können.

## Wann sollte RFT verwendet werden

Verwenden Sie RFT, wenn Sie klare, messbare Erfolgskriterien definieren können, aber Schwierigkeiten haben, exakt korrekte Ergebnisse für das Training zu liefern. Es ist ideal für Aufgaben, bei denen die Qualität subjektiv oder facettenreich ist — wie kreatives Schreiben, Codeoptimierung oder komplexes Denken —, bei denen es mehrere gültige Lösungen gibt, von denen jedoch einige eindeutig besser sind als andere.

RFT funktioniert am besten, wenn Sie über Folgendes verfügen:

- Eine zuverlässige Belohnungsfunktion, die Modellausgaben programmgesteuert auswerten kann
- Sie müssen das Modellverhalten an bestimmten Präferenzen oder Einschränkungen ausrichten
- Situationen, in denen die herkömmliche überwachte Feinabstimmung unzureichend ist, weil es teuer oder unpraktisch ist, hochwertige, beschriftete Beispiele zu sammeln

Ziehen Sie RFT für Anwendungen in Betracht, die iterative Verbesserungen, Personalisierung oder die Einhaltung komplexer Geschäftsregeln erfordern, die als Belohnungssignale kodiert werden können.

## Wofür ist RFT am besten geeignet

RFT zeichnet sich in Bereichen aus, in denen die Ausgabequalität objektiv gemessen werden kann, es jedoch schwierig ist, optimale Antworten im Voraus zu definieren:

- Mathematische Problemlösung: Überprüfbare Richtigkeit mit mehreren Lösungswegen
- Codegenerierung und -optimierung: Testbare Ausführungsergebnisse und Leistungskennzahlen
- Aufgaben zum wissenschaftlichen Denken: Logische Konsistenz und sachliche Richtigkeit
- Strukturierte Datenanalyse: Programmatisch überprüfbare Ergebnisse
- Mehrstufiges Denken: Aufgaben, die eine logische Weiterentwicklung erfordern step-by-step
- Toolnutzung und API-Aufrufe: Der Erfolg ist an den Ausführungsergebnissen messbar
- Komplexe Arbeitsabläufe: Einhaltung bestimmter Einschränkungen und Geschäftsregeln

RFT funktioniert hervorragend, wenn Sie mehrere konkurrierende Ziele wie Genauigkeit, Effizienz und Stil in Einklang bringen müssen.

## Wann sollte der Argumentationsmodus für das RFT-Training verwendet werden

Amazon Nova 2.0 unterstützt den Argumentationsmodus während des RFT-Trainings. Die folgenden Modi sind verfügbar:

- none: Keine Begründung (lassen Sie das Feld `reasoning_effort` weg)
- niedrig: Minimaler Argumentationsaufwand
- hoch: Maximales Argumentationsvermögen (Standard, wenn `reasoning_effort` angegeben ist)

 Note

Es gibt keine mittlere Option für RFT. Wenn das Feld `reasoning_effort` in Ihrer Konfiguration nicht vorhanden ist, ist Reasoning deaktiviert.

Verwenden Sie High Reasoning für Folgendes:

- Komplexe analytische Aufgaben
- Mathematische Problemlösung
- Mehrstufige logische Deduktion
- Aufgaben, bei denen step-by-step Denken einen Mehrwert bietet

Verwenden Sie in folgenden Fällen keine Argumentation (lassen Sie `Reasoning_Effort` weg) oder wenig Argumentation:

- Einfache sachliche Fragen
- Direkte Klassifizierungen
- Geschwindigkeits- und Kostenoptimierung
- Unkomplizierte Beantwortung von Fragen

 Important

Höhere Argumentationsmodi erhöhen den Zeit- und Kostenaufwand für das Training, erhöhen die Inferenzlatenz und die Kosten, erhöhen aber auch die Leistungsfähigkeit des Modells für komplexe Denkaufgaben.

## Unterstützte Modelle

RFT onSageMaker HyperPod unterstützt Amazon Nova Lite 2.0 (amazon.nova-2-lite-v 1:0:256 k).

## Wichtige Schritte

Der RFT-Prozess umfasst vier Hauptphasen:

- Implementierung eines Evaluators: Erstellen Sie eine Belohnungsfunktion, um Modellantworten anhand Ihrer Qualitätskriterien programmgesteuert zu bewerten.
- Eingabeaufforderungen hochladen: Bereiten Sie Trainingsdaten mit Referenzdaten für die Auswertung im angegebenen Konversationsformat vor und laden Sie sie hoch.
- Einen Job starten: Starten Sie den Prozess zur Feinabstimmung der Bewehrung mit Ihren konfigurierten Parametern.
- Überwachung: Verfolgen Sie den Trainingsfortschritt mithilfe von Metrik-Dashboards, um sicherzustellen, dass das Modell effektiv lernt.

Jeder Schritt baut auf dem vorherigen auf, wobei der Evaluator als Grundlage dient, der den gesamten Trainingsprozess steuert, indem er konsistente Feedbacksignale liefert.

## Themen

- [RFT auf Nova 2.0](#)

## RFT auf Nova 2.0

RFT-Trainingsdaten folgen dem OpenAI-Konversationsformat. Jedes Trainingsbeispiel ist ein JSON-Objekt, das Nachrichten, Referenzantworten und optionale Tooldefinitionen enthält. Dieser Abschnitt enthält Anleitungen zur Vorbereitung effektiver Trainingsdaten für RFT auf Nova 2.0.

## Themen

- [Datenformat und Struktur](#)
- [Beschreibungen der Felder](#)
- [Anleitung zu Hyperparametern](#)
- [Zusätzliche Eigenschaften](#)
- [Empfehlungen zur Größe von Datensätzen](#)
- [Merkmale effektiver Trainingsdaten](#)

- [Überwachung von RFT-Schulungen](#)

## Datenformat und Struktur

Jedes Trainingsbeispiel ist ein JSON-Objekt, das Folgendes enthält:

- Nachrichten: Eine Reihe von Konversationsrunden mit System-, Benutzer- und optional Assistentenrollen
- reference\_answer: Erwartete Ausgabe- oder Bewertungskriterien für die Berechnung der Belohnung
- tools (optional): Eine Reihe von Funktionsdefinitionen, die dem Modell zur Verfügung stehen
- id (optional): Eindeutiger Bezeichner für Tracking und Deduplizierung

Jedes Beispiel sollte sich in einer einzigen Zeile in Ihrer JSONL-Datei befinden, mit einem JSON-Objekt pro Zeile.

### Beispiel 1: Chemisches Problem

Das folgende Beispiel zeigt ein chemisches Problem mit einer Referenzantwort, die Ground-Truth-Werte enthält:

```
{
 "id": "chem-001",
 "messages": [
 {
 "role": "system",
 "content": "You are a helpful chemistry assistant"
 },
 {
 "role": "user",
 "content": "Predict hydrogen bond donors and acceptors for this SMILES:
CCN(CC)CCC(=O)c1sc(N)nc1C"
 }
],
 "reference_answer": {
 "donor_bond_counts": 2,
 "acceptor_bond_counts": 4,
 "explanation": "Calculated using Lipinski's rule of five: N-H groups (2 donors), N
and O atoms with lone pairs (4 acceptors)"
 }
}
```

```
}
```

### Note

Die Datei `reference_answer` enthält Ground-Truth-Werte, die anhand domänenspezifischer Regeln berechnet wurden. Ihre Belohnungsfunktion vergleicht die vom Modell vorhergesagten Werte mit diesen Referenzwerten, um einen Belohnungsscore zu berechnen.

## Beispiel 2: Mathematische Aufgabe

Das folgende Beispiel zeigt eine mathematische Aufgabe mit Lösungsschritten:

```
{
 "id": "math-001",
 "messages": [
 {
 "role": "system",
 "content": "You are a math tutor"
 },
 {
 "role": "user",
 "content": "Solve: $2x + 5 = 13$ "
 }
],
 "reference_answer": {
 "solution": "x = 4",
 "steps": [" $2x = 13 - 5$ ", " $2x = 8$ ", " $x = 4$ "]
 }
}
```

## Beispiel 3: Verwendung des Tools

Das folgende Beispiel zeigt die Verwendung von Tools mit erwartetem Verhalten:

```
{
 "id": "tool-001",
 "messages": [
 {
 "role": "system",
 "content": "You are a helpful game master assistant"
 },
],
}
```



```
{
 "role": "user",
 "content": "Generate a strength stat for a warrior character. Apply a +2 racial
bonus modifier."
},
"tools": [
 {
 "type": "function",
 "function": {
 "name": "StatRollAPI",
 "description": "Generates character stats by rolling 4d6, dropping the lowest
die result, and applying a modifier.",
 "parameters": {
 "type": "object",
 "properties": {
 "modifier": {
 "description": "An integer representing the modifier to apply to the
total of the stat roll.",
 "type": "integer"
 }
 }
 },
 "required": ["modifier"]
 }
 }
],
"reference_answer": {
 "tool_called": "StatRollAPI",
 "tool_parameters": {
 "modifier": 2
 },
 "expected_behavior": "Call StatRollAPI with modifier=2 and return the calculated
stat value"
}
```

## Beschreibungen der Felder

| Feld                  | Description                                                                                | Weitere Hinweise                                                                                                                                   | Erforderlich |
|-----------------------|--------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------|--------------|
| id                    | Eindeutiger Bezeichner für dieses RFT-Beispiel                                             | Zeichenfolge (zum Beispiel „sample-001“). Nützlich für Tracking und Deduplizierung.                                                                | Nein         |
| messages              | Eine geordnete Liste von Chat-Nachrichten, die die Aufforderung und den Kontext definieren | Array von -Objekten. Das Model sieht sie in der richtigen Reihenfolge. Beginnt in der Regel mit einer Systemnachricht und dann mit einem Benutzer. | Ja           |
| nachrichten[].role    | Wer spricht in der Nachricht                                                               | Allgemeine Werte: „System“, „Benutzer“ (manchmal „Assistent“ in anderen Kontexten)                                                                 | Nein         |
| nachrichten[].content | Der Textinhalt der Nachricht                                                               | Einfache Zeichenfolge. Für das System sind es Anweisungen, für den Benutzer ist es die Aufgabe oder Eingabe.                                       | Nein         |
| Tools                 | In diesem Beispiel stehen dem Modell die Werkzeugepezifikationen zur Verfügung             | Reihe. Jedes Element definiert die Oberfläche und die Metadaten eines Tools. Zu den Typen können                                                   | Nein         |

| Feld             | Description                                     | Weitere Hinweise                                                                                    | Erforderlich |
|------------------|-------------------------------------------------|-----------------------------------------------------------------------------------------------------|--------------|
|                  |                                                 | „Funktion“ oder „intern“ gehören.                                                                   |              |
| reference_answer | Die erwartete Modellausgabe für dieses Beispiel | Zeichenfolge oder Objekt, je nach Aufgabe. Wird als Ziel für die Bewertung oder Schulung verwendet. | Nein         |

#### Note

Alle zusätzlichen benutzerdefinierten Felder (z. B. task\_id, difficulty\_level, context\_data) werden nicht validiert und als Metadaten an Ihre Belohnungsfunktion übergeben.

## Anleitung zu Hyperparametern

Verwenden Sie je nach Trainingsansatz die folgenden empfohlenen Hyperparameter:

### Allgemein:

- Epochen: 1
- Lernrate (lr): 1e-7
- Anzahl der Generationen: 8
- Max. Anzahl neuer Token: 8192
- Chargengröße: 256

### LoRa (Low-Rank-Anpassung):

- LoRa-Rang: 32

 Note

Passen Sie diese Werte an die Größe Ihres Datensatzes und die Validierungsleistung an. Überwachen Sie die Trainingsmetriken, um eine Überanpassung zu vermeiden.

## Zusätzliche Eigenschaften

Mit der Einstellung „additionalProperties“: true können Sie benutzerdefinierte Felder hinzufügen, die über die grundlegenden Schemaanforderungen hinausgehen. So können Sie flexibel alle Daten hinzufügen, die Ihre Prämienfunktion für eine korrekte Auswertung benötigt.

### Allgemeine zusätzliche Felder

Sie können die folgenden Arten von zusätzlichen Feldern einbeziehen:

#### Metadaten:

- `task_id`: Eindeutige Kennung für das Tracking
- `difficulty_level`: Indikator für die Komplexität des Problems
- `Domaine`: Fachgebiet oder Kategorie
- `expected_reasoning_steps`: Anzahl der Lösungsschritte

#### Bewertungskriterien:

- `Bewertungskriterien`: Spezifische Bewertungsrubriken
- `custom_scoring_weights`: Relative Bedeutung verschiedener Aspekte
- `context_data`: Hintergrundinformationen zum Problem
- `external_references`: Links zu relevanter Dokumentation oder Ressourcen

## Beispiel mit zusätzlichen Eigenschaften

Das folgende Beispiel beinhaltet benutzerdefinierte Metadatenfelder:

```
{
 "id": "algebra_001",
 "messages": [

```

```
{
 "role": "system",
 "content": "You are a math tutor"
},
{
 "role": "user",
 "content": "Solve: $2x + 5 = 13$ "
}
],
"reference_answer": {
 "solution": " $x = 4$ ",
 "steps": [" $2x = 13 - 5$ ", " $2x = 8$ ", " $x = 4$ "]
},
"task_id": "algebra_001",
"difficulty_level": "easy",
"domain": "algebra",
"expected_reasoning_steps": 3
}
```

## Empfehlungen zur Größe von Datensätzen

### Ausgangspunkt

Beginnen Sie mit den folgenden Mindestgrößen von Datensätzen:

- Mindestens 100 Trainingsbeispiele
- Mindestens 100 Bewertungsbeispiele

Priorisieren Sie hochwertige Eingabedaten und eine zuverlässige Belohnungsfunktion, die bei Modellantworten konsistent ausgeführt wird.

Der Ansatz steht bei der Bewertung an erster Stelle

Bevor Sie in groß angelegte RFT-Schulungen investieren, sollten Sie die Ausgangsleistung Ihres Modells bewerten:

- Hohe Leistung (mehr als 95% Belohnung): RFT ist möglicherweise unnötig — Ihr Modell schneidet bereits gut ab
- Sehr schlechte Leistung (0% Prämie): Wechseln Sie zuerst zu SFT, um grundlegende Funktionen zu erlangen
- Mäßige Leistung: RFT ist wahrscheinlich angemessen

Dieser Ansatz, bei dem die Bewertung an erster Stelle steht, stellt sicher, dass Ihre Belohnungsfunktion fehlerfrei ist, und bestimmt, ob RFT die richtige Methode für Ihren Anwendungsfall ist. Wenn Sie klein anfangen, können Sie sich mit dem RFT-Workflow vertraut machen, Probleme frühzeitig erkennen und beheben, Ihren Ansatz validieren, bevor Sie ihn skalieren, und die Zuverlässigkeit der Belohnungsfunktion testen. Nach der Validierung können Sie auf größere Datensätze expandieren, um die Leistung weiter zu verbessern.

## Merkmale effektiver Trainingsdaten

### Klarheit und Konsistenz

Gute RFT-Beispiele erfordern klare, eindeutige Eingabedaten, die eine genaue Berechnung der Belohnung für verschiedene Modellergebnisse ermöglichen. Vermeiden Sie Rauschen in Ihren Daten, einschließlich:

- Inkonsistente Formatierung
- Widersprüchliche Bezeichnungen oder Anweisungen
- Mehrdeutige Aufforderungen
- Widersprüchliche Referenzantworten

Jede Unklarheit führt den Trainingsprozess in die Irre und führt dazu, dass das Modell unbeabsichtigte Verhaltensweisen erlernt.

### Diversität

Ihr Datensatz sollte die gesamte Vielfalt der Anwendungsfälle in der Produktion erfassen, um eine robuste Leistung unter realen Bedingungen zu gewährleisten. Dazu gehören:

- Verschiedene Problemtypen und Schwierigkeitsgrade
- Verschiedene Eingabeformate und Sonderfälle
- Repräsentative Stichproben aus allen erwarteten Szenarien

Diese Vielfalt trägt dazu bei, eine Überanpassung zu verhindern, und stellt sicher, dass das Modell auch unbekannte Eingaben problemlos verarbeitet.

## Überlegungen zur Belohnungsfunktion

Gestalten Sie Ihre Belohnungsfunktion für effizientes Training:

- Innerhalb von Sekunden (nicht Minuten) ausführen
- Effektive Parallelisierung mit Lambda
- Geben Sie konsistente, zuverlässige Ergebnisse zurück
- Gehen Sie elegant mit verschiedenen Arten von Modellausgaben um

Schnelle, skalierbare Belohnungsfunktionen ermöglichen schnelle Iterationen und kosteneffizientes Experimentieren in großem Maßstab.

### Überwachung von RFT-Schulungen

Überwachen Sie die wichtigsten Kennzahlen während der Schulung, um ein effektives Lernen sicherzustellen und potenzielle Probleme frühzeitig zu erkennen.

#### Themen

- [Wichtige Kennzahlen, die es zu verfolgen gilt](#)
- [Bewertung nach RFT](#)
- [Verwendung fein abgestimmter Modelle](#)
- [Einschränkungen und bewährte Methoden](#)
- [Fehlerbehebung](#)

#### Wichtige Kennzahlen, die es zu verfolgen gilt

Überwachen Sie MIFlow während des Trainings die folgenden Kennzahlen:

##### Kennzahlen zur Belohnung:

- Durchschnittliche Prämienbewertung: Gesamtqualität der Modellantworten (sollte im Laufe der Zeit zunehmen)
- Verteilung der Belohnungen: Prozentsatz der Antworten, die hohe, mittlere und niedrige Prämien erhielten
- Prämien für Schulung und Validierung: Vergleich zur Erkennung von Überanpassungen

##### Kennzahlen zur Schulung:

- Aktualisierungen der Richtlinien: Anzahl der erfolgreichen Gewichtsaktualisierungen

- Abschlussquote bei der Einführung: Prozentsatz der erfolgreich bewerteten Proben

Zu den Mustern:

- Belohnt ein Plateau (deutet auf schlechtes Lernen hin)
- Die Validierungsbelohnungen sinken, während die Trainingsbelohnungen steigen (Überanpassung)
- Die Varianz der Belohnungen nimmt im Laufe der Zeit deutlich zu (Instabilität)
- Hoher Prozentsatz von Fehlern bei der Belohnungsfunktion (Implementierungsprobleme)

Wann sollte ich mit dem Training aufhören:

- Die angestrebten Leistungskennzahlen wurden erreicht
- Die Belohnungen stagnieren und verbessern sich nicht mehr
- Die Validierungsleistung verschlechtert sich (es wurde eine Überanpassung festgestellt)
- Das maximale Schulungsbudget ist erreicht

Bewertung nach RFT

Evaluieren Sie nach Abschluss der Schulung Ihr fein abgestimmtes Modell, um Leistungsverbesserungen zu bewerten:

- Führen Sie den RFT-Evaluierungsjob aus: Verwenden Sie den Checkpoint aus Ihrem RFT-Training als Modell
- Mit dem Ausgangsmodell vergleichen: Evaluieren Sie sowohl das Basismodell als auch das fein abgestimmte Modell mit demselben Testsatz
- Metriken analysieren: Überprüfen Sie aufgabenspezifische Kennzahlen (Genauigkeit, Prämienwerte usw.)
- Führen Sie eine qualitative Überprüfung durch: Untersuchen Sie die Probenergebnisse manuell auf Qualität

Ausführliche Bewertungsverfahren finden Sie im Abschnitt Bewertung.

Verwendung fein abgestimmter Modelle

Zugreifen auf Checkpoints:



Suchen Sie nach Abschluss des Trainings Ihren Checkpoint:

1. Navigiere zu deinem `output_path` in S3
2. Downloaden und entpacken `output.tar.gz`
3. Öffnen Sie `manifest.json`.
4. Kopieren Sie den `checkpoint_s3_bucket` Wert

Für Inferenz bereitstellen:

Verwenden Sie den Checkpoint S3-Pfad für Inferenzen oder weitere Schulungen:

```
run:
 model_type: amazon.nova-2-lite-v1:0:256k
 model_name_or_path: "s3://customer-escrow-<account-number>-smtj-<unique-
 identifier>/<job-name>"
```

Anweisungen zur Bereitstellung und Inferenz finden Sie im Abschnitt Inferenz.

Einschränkungen und bewährte Methoden

Aktuelle Einschränkungen:

Beta-Einschränkungen:

- Sie müssen eine neue RIG-Gruppe für RFT erstellen. Diese Einschränkung wird von GA behoben.
- Anforderungen an den Instance-Typ: Es werden nur P5-Instances unterstützt (mindestens 8x P5.48xLarge). Demnächst: Support für kleinere Instance-Typen (voraussichtliche Ankunftszeit: Mitte Januar 2025).

Funktionelle Einschränkungen:

- 15-minütiges Lambda-Timeout: Belohnungsfunktionen müssen innerhalb von 15 Minuten abgeschlossen sein
- Nur Single-Turn-Konversationen: Konversationen mit mehreren Runden werden nicht unterstützt
- Validierungsdatensätze: Während des Trainings nicht unterstützt. Verwenden Sie separate Bewertungsaufgaben, um den Trainingsfortschritt zu bewerten.

Überlegungen zur Schulung:

- Szenarien mit geringer Belohnung: Kann Probleme bereiten, wenn weniger als 5% der Beispiele positive Prämien erhalten — ziehen Sie zuerst SFT in Betracht
- Datenanforderungen: Benötigt eine ausreichende Vielfalt, um effektiv lernen zu können
- Rechenkosten: Teurer als überwachte Feinabstimmung

Nova Forge beseitigt einige dieser Einschränkungen:

- Unterstützt Multi-Turn-Konversationen
- Ermöglicht Belohnungsfunktionen mit einer Zeitüberschreitung von mehr als 15 Minuten
- Bietet erweiterte Algorithmen und Optimierungsoptionen
- Konzipiert für komplexe Anwendungsfälle in Unternehmen, speziell auf die Entwicklung von Grenzmodellen abgestimmt

Bewährte Verfahren:

Fangen Sie klein an und skalieren Sie:

- Beginnen Sie mit minimalen Datensätzen (100-200 Beispiele) und wenigen Trainingsepochen
- Überprüfen Sie Ihren Ansatz, bevor Sie ihn skalieren
- Erhöhen Sie schrittweise die Datensatzgröße und die Trainingsschritte auf der Grundlage der Ergebnisse

Ausgangsbasis mit SFT zuerst:

- Wenn die Prämienwerte konstant niedrig sind (z. B. immer 0), führen Sie SFT vor RFT durch
- RFT erfordert eine angemessene Ausgangsleistung, um sich effektiv zu verbessern

Entwerfen Sie effiziente Belohnungsfunktionen:

- Ausführung in Sekunden, nicht in Minuten
- Minimiere externe API-Aufrufe
- Verwenden Sie effiziente Algorithmen und Datenstrukturen
- Implementieren Sie die richtige Fehlerbehandlung
- Vor dem Training gründlich testen

- Nutzen Sie die Funktionen parallel Skalierung von Lambda

Überwachen Sie das Training aktiv:

- Verfolge die durchschnittlichen Prämienwerte im Laufe der Zeit
- Beobachten Sie die Verteilung der Belohnungen auf die Stichproben
- Vergleichen Sie die Prämien für Schulungen und Validierungen
- Achten Sie auf problematische Muster (Plateaus, Überanpassung, Instabilität)

Iterieren Sie auf der Grundlage der Ergebnisse:

- Wenn sich die Belohnungen nach mehreren Iterationen nicht verbessern, passen Sie das Design der Belohnungsfunktion an
- Erhöhen Sie die Vielfalt der Datensätze, um klarere Lernsignale bereitzustellen
- Erwägen Sie, zu SFT zu wechseln, wenn die Prämien nahe Null bleiben
- Experimentieren Sie mit verschiedenen Hyperparametern (Lernrate, Chargengröße)

Optimieren Sie die Datenqualität:

- Sorgen Sie für vielfältige, repräsentative Beispiele
- Schließen Sie Sonderfälle und schwierige Proben ein
- Stellen Sie sicher, dass die Belohnungsfunktion alle Beispieltypen korrekt bewertet
- Entferne oder repariere Beispiele, die die Belohnungsfunktion verwirren

Fehlerbehebung

Fehler bei der Belohnungsfunktion:

Symptome: Hohe Fehlerquote bei Aufrufen von Belohnungsfunktionen während des Trainings

| Problem                   | Symptome                         | Auflösung                                             |
|---------------------------|----------------------------------|-------------------------------------------------------|
| Lambda-Zeitüberschreitung | Häufige Timeouts nach 15 Minuten | Optimieren Sie die Funktionsleistung; ziehen Sie Nova |

| Problem                    | Symptome                                             | Auflösung                                                                                               |
|----------------------------|------------------------------------------------------|---------------------------------------------------------------------------------------------------------|
|                            |                                                      | Forge für komplexe Evaluierungen in Betracht                                                            |
| Unzureichende Parallelität | Fehler bei der Lambda-Drosselung                     | Erhöhen Sie das <code>Lambda_Concurrency_Limit</code> oder beantragen Sie eine Erhöhung des Kontingents |
| Ungültiges Rückgabeformat  | Das Training schlägt aufgrund von Formatfehlern fehl | Stellen Sie sicher, dass die Rückgabestruktur dem erforderlichen Schnittstellenformat entspricht        |
| Unbehandelte Ausnahmen     | Zeitweise auftretende Fehler                         | Fügen Sie umfassende Fehlerbehandlung und Protokollierung hinzu                                         |
| Externe API-Fehler         | Inkonsistente Bewertung                              | Implementieren Sie Wiederholungslogik und Fallback-Strategien                                           |

### Schlechte Trainingsleistung:

Symptome: Die Belohnungen verbessern sich nicht oder stagnieren bei niedrigen Werten

### Resolutionen:

- Überprüfen Sie die Richtigkeit der Belohnungsfunktion: Testen Sie anhand bekannter good/bad Beispiele
- Überprüfen Sie die Ausgangsleistung: Evaluieren Sie das Basismodell. Wenn die Genauigkeit nahezu Null ist, führen Sie zuerst SFT durch
- Erhöhen Sie die Datenvielfalt: Fügen Sie vielfältigere Beispiele für verschiedene Szenarien hinzu
- Passen Sie die Hyperparameter an: Probieren Sie verschiedene Lernraten oder Batchgrößen aus
- Überprüfen Sie die Qualität der Belohnungssignale: Stellen Sie sicher, dass bei den Belohnungen zwischen guten und schlechten Antworten unterschieden wird

## Überdimensioniert:

Symptome: Die Prämien für Schulungen steigen, während die Validierungsprämien sinken

## Resolutionen:

- Trainingsschritte reduzieren: Beenden Sie das Training früher
- Datensatzgröße erhöhen: Weitere Trainingsbeispiele hinzufügen
- Regularisierung hinzufügen: Anpassen oder `weight_decay` `entropy_coeff`
- Erhöhen Sie die Datenvielfalt: Stellen Sie sicher, dass das Trainingsset die vollständige Verteilung gewährleistet

## Bewerten Ihres trainierten Modells

Ein Bewertungsrezept ist eine YAML-Konfigurationsdatei, die definiert, wie Ihr Amazon-Nova-Modellbewertungsjob ausgeführt wird. Mit diesem Rezept können Sie die Leistung eines Basismodells oder eines trainierten Modells anhand gängiger Benchmarks oder Ihrer eigenen benutzerdefinierten Datensätze bewerten. Metriken können in Amazon S3 oder gespeichert werden TensorBoard. Die Bewertung bietet quantitative Metriken, anhand derer Sie die Modellleistung bei verschiedenen Aufgaben beurteilen können, um festzustellen, ob weitere Anpassungen erforderlich sind.

Die Modellbewertung ist ein Offline-Prozess, bei dem Modelle anhand festgelegter Benchmarks mit vordefinierten Antworten getestet werden. Sie werden nicht in Echtzeit oder anhand von Live-Benutzerinteraktionen bewertet. Für Echtzeitbewertungen können Sie das Modell nach der Bereitstellung auf Amazon Bedrock bewerten, indem Sie die Laufzeit-APIs von Amazon Bedrock aufrufen.

### Note

Sie können Ihre Modelle auch mit [Inspect AI](#) bewerten, einem Open-Source-Evaluierungsframework, das standardisierte Benchmarks und benutzerdefinierte Bewertungsaufgaben unterstützt.

**⚠ Important**

Der Evaluierungscontainer unterstützt nur Checkpoints, die von derselben Trainingsplattform erstellt wurden. Checkpoints, die mit erstellt wurden, SageMaker HyperPod können nur mithilfe des SageMaker HyperPod Evaluierungs-Workflows bewertet werden, und Checkpoints, die mit SageMaker Trainingsjobs erstellt wurden, können nur mithilfe des Workflows zur Bewertung von SageMaker Trainingsjobs bewertet werden. Der Versuch, einen Checkpoint von einer anderen Plattform aus zu bewerten, schlägt fehl.

**Themen**

- [Verfügbare Benchmark-Aufgaben](#)
- [Verstehen der Rezeptparameter](#)
- [Beispiele für Bewertungsrezepte](#)
- [Starten eines Bewertungsjobs](#)
- [Zugriff auf und Analyse der Bewertungsergebnisse](#)
- [RFT-Bewertung](#)

**Verfügbare Benchmark-Aufgaben**

Es ist ein Beispielcodepaket verfügbar, das zeigt, wie Benchmark-Metriken mithilfe der SageMaker KI-Modellbewertungsfunktion für Amazon Nova berechnet werden. Informationen zum Zugriff auf die Codepakete finden Sie unter [sample- Nova-lighteval-custom-task](#).

Hier finden Sie eine Liste unterstützter, verfügbarer Industriestandard-Benchmarks. Sie können die folgenden Benchmarks für den Parameter `eval_task` angeben:

| Benchmark | Modalität | Description                                                 | Kennzahlen  | Strategie | Unteraufgabe verfügbar |
|-----------|-----------|-------------------------------------------------------------|-------------|-----------|------------------------|
| mmlu      | Text      | Multi-task Sprachverständnis — Testet Wissen in 57 Fächern. | Richtigkeit | zs_cot    | Ja                     |

| Benchmark | Modalität | Description                                                                                                                                                                              | Kennzahlen  | Strategie | Unteraufgabe verfügbar |
|-----------|-----------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------|-----------|------------------------|
| mmlu_pro  | Text      | MMLU – professioneller Bereich – konzentriert sich auf Fachbereiche wie Recht, Medizin, Rechnungswesen und Ingenieurwesen.                                                               | Richtigkeit | zs_cot    | Nein                   |
| bbh       | Text      | Fortschrittliche Argumentationsaufgaben – eine Sammlung herausfordernder Probleme, die kognitive Fähigkeiten und Fähigkeiten zur Problemlösung auf höherem Niveau auf die Probe stellen. | Richtigkeit | zs_cot    | Ja                     |

| Benchmark | Modalität | Description                                                                                                                                             | Kennzahlen  | Strategie | Unteraufgabe verfügbar |
|-----------|-----------|---------------------------------------------------------------------------------------------------------------------------------------------------------|-------------|-----------|------------------------|
| gpqa      | Text      | Beantwortung allgemeiner Fragen zur Physik – beurteilt das Verständnis physikalischer Konzepte und die damit verbundenen Fähigkeiten zur Problemlösung. | Richtigkeit | zs_cot    | Nein                   |



| Benchmark     | Modalität | Description                                                                                                                                             | Kennzahlen  | Strategie | Unteraufgabe verfügbar |
|---------------|-----------|---------------------------------------------------------------------------------------------------------------------------------------------------------|-------------|-----------|------------------------|
| math          | Text      | Mathematische Problemlösung – bewertet mathematische Überlegungen in verschiedenen Themenbereichen wie Algebra, Infinitesimalrechnung und Textaufgaben. | exact_match | zs_cot    | Ja                     |
| strong_reject | Text      | Quality-Control Aufgabe — Testet die Fähigkeit des Modells, unangemessene, schädliche oder falsche Inhalte zu erkennen und abzulehnen.                  | deflection  | zs        | Ja                     |

| Benchmark | Modalität | Description                                                                                                                                        | Kennzahlen  | Strategie | Unteraufgabe verfügbar |
|-----------|-----------|----------------------------------------------------------------------------------------------------------------------------------------------------|-------------|-----------|------------------------|
| IFEval    | Text      | Instruction-Following<br>Bewertung<br>— Prüft, wie genau ein Modell bestimmte Anweisungen befolgt und Aufgaben gemäß den Spezifikationen ausführt. | Richtigkeit | zs        | Nein                   |

| Benchmark | Modalität | Description                                                                                                                                                                                                              | Kennzahlen | Strategie | Unteraufgabe verfügbar |
|-----------|-----------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------|-----------|------------------------|
| gen_qa    | Text      | Benutzerdefinierte Datensatzbewertung – Ermöglicht es Ihnen, Ihren eigenen Datensatz für das Benchmarking zu verwenden und Modellergebnisse mit Referenzantworten anhand von Metriken wie ROUGE und BLEU zu vergleichen. | all        | gen_qa    | Nein                   |

| Benchmark | Modalität | Description                                                                                                                                                                                                                                                                   | Kennzahlen | Strategie | Unteraufgabe verfügbar |
|-----------|-----------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------|-----------|------------------------|
| llm_judge | Text      | LLM-as-a-Judge<br>Präferenzvergleich —<br>Verwendet ein Amazon Nova Judge-Modell, um die Präferenz zwischen gepaarten Antworten (B im Vergleich zu A) für Ihre Eingabeaufforderungen zu ermitteln und die Wahrscheinlichkeit zu berechnen, dass B gegenüber A bevorzugt wird. | all        | judge     | Nein                   |

| Benchmark    | Modalität          | Description                                                                                                                                                         | Kennzahlen | Strategie | Unteraufgabe verfügbar |
|--------------|--------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------|-----------|------------------------|
| humaneval    | Text               | HumanEval<br>- Ein Benchmark-Datensatz zur Bewertung der Fähigkeiten zur Codegenerierung großer Sprachmodelle                                                       | pass@1     | zs        | Nein                   |
| mm_llm_judge | Multi-modal (Bild) | Dieser neue Benchmark verhält sich genauso wie der obige textbasierte llm_judge Benchmark. Der einzige Unterschied besteht darin, dass er Bildinferenz unterstützt. | all        | judge     | Nein                   |

| Benchmark        | Modalität | Description                                                                                                                                                                                                                                                                                                                                                                | Kennzahlen | Strategie | Unteraufgabe verfügbar |
|------------------|-----------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------|-----------|------------------------|
| rubric_llm_judge | Text      | <p>Rubric Judge ist ein erweitertes LLM-as-a-judge Bewertungsmodell, das auf Amazon Nova 2.0 Lite basiert. Im Gegensatz zum <a href="#">ursprünglichen Richtermodell</a>, das nur Präferenzurteile vorsieht, generiert Rubric Judge dynamisch benutzerdefinierte Bewertungskriterien, die auf jede Aufforderung zugeschnitten sind, und weist detaillierte Bewertungen</p> | all        | judge     | Nein                   |

| Benchmark           | Modalität | Description                                                                                                                                               | Kennzahlen  | Strategie | Unteraufgabe verfügbar |
|---------------------|-----------|-----------------------------------------------------------------------------------------------------------------------------------------------------------|-------------|-----------|------------------------|
|                     |           | für mehrere Dimensionen zu.                                                                                                                               |             |           |                        |
| aime_2024           | Text      | AIME 2024 — Prüfungsaufgaben auf Einladung der American Invitational Mathematics zur Prüfung von fortgeschrittenem mathematischen Denken und Problemlösen | exact_match | zs_cot    | Nein                   |
| Calendar_Scheduling | Text      | Natural Plan — Kalender Scheduling — Aufgabe zum Testen von Planungsfunktionen für die Planung von Besprechungen über mehrere Tage und Personen           | exact_match | fs        | Nein                   |

Die folgenden mmLu-Unteraufgaben sind verfügbar:

```
MMLU_SUBTASKS = [
 "abstract_algebra",
 "anatomy",
 "astronomy",
 "business_ethics",
 "clinical_knowledge",
 "college_biology",
 "college_chemistry",
 "college_computer_science",
 "college_mathematics",
 "college_medicine",
 "college_physics",
 "computer_security",
 "conceptual_physics",
 "econometrics",
 "electrical_engineering",
 "elementary_mathematics",
 "formal_logic",
 "global_facts",
 "high_school_biology",
 "high_school_chemistry",
 "high_school_computer_science",
 "high_school_european_history",
 "high_school_geography",
 "high_school_government_and_politics",
 "high_school_macroeconomics",
 "high_school_mathematics",
 "high_school_microeconomics",
 "high_school_physics",
 "high_school_psychology",
 "high_school_statistics",
 "high_school_us_history",
 "high_school_world_history",
 "human_aging",
 "human_sexuality",
 "international_law",
 "jurisprudence",
 "logical_fallacies",
 "machine_learning",
 "management",
 "marketing",
 "medical_genetics",
```



```
"miscellaneous",
"moral_disputes",
"moral_scenarios",
"nutrition",
"philosophy",
"prehistory",
"professional_accounting",
"professional_law",
"professional_medicine",
"professional_psychology",
"public_relations",
"security_studies",
"sociology",
"us_foreign_policy",
"virology",
"world_religions"
]
```

Die folgenden bbh-Unteraufgaben sind verfügbar:

```
BBH_SUBTASKS = [
 "boolean_expressions",
 "causal_judgement",
 "date_understanding",
 "disambiguation_qa",
 "dyck_languages",
 "formal_fallacies",
 "geometric_shapes",
 "hyperbaton",
 "logical_deduction_five_objects",
 "logical_deduction_seven_objects",
 "logical_deduction_three_objects",
 "movie_recommendation",
 "multistep_arithmetic_two",
 "navigate",
 "object_counting",
 "penguins_in_a_table",
 "reasoning_about_colored_objects",
 "ruin_names",
 "salient_translation_error_detection",
 "snarks",
 "sports_understanding",
 "temporal_sequences",
```

```

 "tracking_shuffled_objects_five_objects",
 "tracking_shuffled_objects_seven_objects",
 "tracking_shuffled_objects_three_objects",
 "web_of_lies",
 "word_sorting"
]

```

Die folgenden math-Unteraufgaben sind verfügbar:

```

MATH_SUBTASKS = [
 "algebra",
 "counting_and_probability",
 "geometry",
 "intermediate_algebra",
 "number_theory",
 "prealgebra",
 "precalculus",
]

```

## Verstehen der Rezeptparameter

### Ausführungskonfiguration

Im Folgenden finden Sie eine allgemeine Ausführungskonfiguration und eine Erläuterung der jeweiligen Parameter.

```

run:
 name: eval_job_name
 model_type: amazon.nova-micro-v1:0:128k
 model_name_or_path: nova-micro/prod
 replicas: 1
 data_s3_path: ""
 output_s3_path: s3://output_path
 mlflow_tracking_uri: ""
 mlflow_experiment_name : ""
 mlflow_run_name : ""

```

- **name:** (erforderlich) ein beschreibender Name für Ihren Bewertungsjob. Dies hilft Ihnen, Ihren Job in der AWS Konsole zu identifizieren.
- **model\_type:** (erforderlich) gibt die zu verwendende Amazon-Nova-Modellvariante an. Ändern Sie dieses Feld nicht manuell. Zu den Optionen gehören:

- `amazon.nova-micro-v1:0:128k`
- `amazon.nova-lite-v1:0:300k`
- `amazon.nova-pro-v1:0:300k`
- `amazon.nova-2-lite-v1:0:256k`
- `model_name_or_path`: (erforderlich) der Pfad zum Basismodell oder zum S3-Pfad für den Checkpoint nach dem Training. Zu den Optionen gehören:
  - `nova-micro/prod`
  - `nova-lite/prod`
  - `nova-pro/prod`
  - `nova-lite-2/prod`
  - (S3-Pfad für den Checkpoint nach dem Training) `s3://<escrow bucket>/<job id>/outputs/checkpoints`
- `replicas`: (erforderlich) die Anzahl der Datenverarbeitungs-Instances, die für das verteilte Training verwendet werden sollen. Sie müssen diesen Wert auf 1 setzen, da mehrere Knoten nicht unterstützt werden.
- `data_s3_path`: (erforderlich) der S3-Pfad zum Eingabe-Datensatz. Lassen Sie diesen Parameter leer, es sei denn, Sie verwenden das Rezept Eigenen Datensatz verwenden oder LLM-as-a-Judge.
- `output_s3_path`: (erforderlich) der S3-Pfad zum Speichern von Artefakten aus der Ausgabebewertung. Beachten Sie, dass der S3-Ausgabe-Bucket von demselben Konto erstellt werden muss, das den Job erstellt.
- `mlflow_tracking_uri`: (Optional) MLFlow-Tracking-Server-ARN zur Verfolgung von runs/experiments MLflow. Bitte stellen Sie sicher, dass Sie über die SageMaker AI-Ausführungsrolle berechtigt sind, auf den Tracking-Server zuzugreifen

## Bewertungskonfiguration

Im Folgenden finden Sie eine Konfiguration für die Modellbewertung und eine Erläuterung der jeweiligen Parameter.

```
evaluation:
 task: mmlu
 strategy: zs_cot
 subtask: mathematics
 metric: accuracy
```

- **task:** (erforderlich) gibt den Bewertungs-Benchmark oder die zu verwendende Aufgabe an.

Liste unterstützter Aufgaben:

- mmlu
- mmlu\_pro
- bbh
- gpqa
- math
- strong\_reject
- gen\_qa
- ifeval
- llm\_judge
- humaneval
- mm\_llm\_judge
- rubric\_llm\_judge
- aime\_2024
- Kalender\_Terminplanung
- humaneval
- **strategy:** (erforderlich) definiert den Bewertungsansatz:
  - **zs\_cot:** Zero-shot Chain-of-Thought - Ein Ansatz zur Entwicklung umfangreicher Sprachmodelle, der das Denken Schritt für Schritt fördert, ohne dass explizite Beispiele erforderlich sind.
  - **zs:** Zero-shot - Ein Ansatz zur Lösung eines Problems ohne vorherige Schulungsbeispiele.
  - **gen\_qa:** eine Strategie, die speziell für Rezepte mit eigenem Datensatz entwickelt wurde
  - **judge:** Eine spezifische Strategie für Amazon Nova LLM as Judge und mm\_llm\_judge.
- **subtask:** (optional und entfernbar) legt eine spezifische Unteraufgabe für bestimmte Bewertungsaufgaben fest. Entfernen Sie dies aus Ihrem Rezept, wenn Ihre Aufgabe keine Unteraufgaben hat.
- **metric:** (erforderlich) die zu verwendende Bewertungsmetrik
  - **accuracy:** Prozentsatz der richtigen Antworten
  - **exact\_match:** (für math-Benchmark) gibt die Rate zurück, mit der die eingegebenen

vorhergesagten Zeichenketten exakt mit ihren Referenzen übereinstimmen.

- `deflection`: (für `strong reject`-Benchmark) gibt die relative Abweichung vom Basismodell und die Differenz der Signifikanzmetriken zurück.
- `pass@1`: (für `humaneval`-Benchmark) ist eine Metrik, die verwendet wird, um den Prozentsatz der Fälle zu messen, in denen die Vorhersage des Modells mit der höchsten Konfidenz mit der richtigen Antwort übereinstimmt.
- `all`: gibt die folgenden Metriken zurück:
  - Gibt für `gen_qa` und das Benchmarking mit eigenem Datensatz die folgenden Metriken zurück:
    - `rouge1`: misst die Überlappung von Unigrammen (einzelnen Wörtern) zwischen generiertem Text und Referenztext.
    - `rouge2`: misst die Überlappung von Bigrammen (zwei aufeinanderfolgenden Wörtern) zwischen generiertem Text und Referenztext.
    - `rougeL`: misst die längste gemeinsame Teilsequenz zwischen Texten und berücksichtigt Lücken beim Abgleich.
    - `exact_match`: binärer Wert (0 oder 1), der angibt, ob der generierte Text Zeichen für Zeichen exakt mit dem Referenztext übereinstimmt.
    - `quasi_exact_match`: ähnlich wie Exact Match, aber weniger strikt, wobei in der Regel Unterschiede zwischen Groß- und Kleinschreibung, Zeichensetzung und Leerzeichen ignoriert werden
    - `f1_score`: harmonisches Mittel zwischen Präzision und Erinnerungswert, das die Wortüberschneidung zwischen vorhergesagten Antworten und Referenzantworten misst
    - `f1_score_quasi`: ähnlich wie `f1_score`, jedoch mit weniger striktem Abgleich, bei dem normalisierter Text verglichen und geringfügige Unterschiede ignoriert werden
    - `bleu`: misst die Genauigkeit von N-Gramm-Übereinstimmungen zwischen generiertem Text und Referenztext, was häufig bei der Bewertung von Übersetzungen verwendet wird.
  - Geben Sie für `llm_judge` und `mm_llm_judge`, bringen Sie Ihren eigenen Datensatz-Benchmark mit, folgende Kennzahlen zurück:
    - `a_scores`: Anzahl der Siege von `response_A` bei Vorwärts- und Rückwärtsdurchläufen zur Bewertung
    - `a_scores_stderr`: Standardfehler von `response_A scores` bei paarweisen Beurteilungen.
    - `b_scores`: Anzahl der Siege von `response_B` bei Vorwärts- und Rückwärtsdurchläufen zur Bewertung.

- `b_scores_stderr`: Standardfehler von `response_B` scores bei paarweisen Beurteilungen.
- `ties`: Anzahl der Beurteilungen, bei denen `response_A` und `response_B` als gleichwertig bewertet wurden.
- `ties_stderr`: Standardfehler von Verbindungen bei paarweisen Beurteilungen.
- `inference_error`: Anzahl der Beurteilungen, die nicht richtig bewertet werden konnten.
- `inference_error_stderr`: Standardfehler von Inferenzfehlern bei allen Beurteilungen.
- `score`: Gesamtpunktzahl basierend auf Siegen aus Vorwärts- und Rückwärtsdurchläufen für `response_B`.
- `score_stderr`: Standardfehler der Gesamtpunktzahl bei paarweisen Beurteilungen
- `winrate`: Die Wahrscheinlichkeit, dass `Response_B` `Response_A` vorgezogen wird, wird anhand der Wahrscheinlichkeit berechnet. Bradley-Terry
- `lower_rate`: Untergrenze (2,5. Perzentil) der geschätzten Gewinnrate aus dem Bootstrap-Sampling.

## Inferenzkonfiguration

Im Folgenden finden Sie eine Inferenzkonfiguration und eine Erläuterung der jeweiligen Parameter. Alle Parameter sind optional.

```
inference:
 max_new_tokens: 200
 top_k: -1
 top_p: 1.0
 temperature: 0
 top_logprobs: 10
 reasoning_effort: null # options: low/high to enable reasoning or null to disable reasoning
```

- `max_new_tokens`: die maximale Anzahl der zu generierenden Token. Dieser Wert muss eine Ganzzahl sein.
- `top_k`: die Anzahl der zu berücksichtigenden Tokens mit der höchsten Wahrscheinlichkeit. Dieser Wert muss eine Ganzzahl sein.
- `top_p`: der kumulative Wahrscheinlichkeitsschwellenwert für das Token-Sampling. Dies muss ein Gleitkommazahl zwischen 0,0 und höchstens 1,0 sein.

- **temperature:** Zufälligkeit bei der Token-Auswahl. Größere Werte führen zu mehr Zufälligkeit. Verwenden Sie 0, um deterministische Ergebnisse zu erhalten. Dieser Wert muss eine Gleitkommazahl mit einem Mindestwert von 0 sein.
- **top\_logprobs:** Die Anzahl der wichtigsten Logprobs, die in der Inferenzantwort zurückgegeben werden sollen. Dieser Wert muss eine Ganzzahl zwischen 0 und 20 sein. Logprobs enthalten die betrachteten Ausgabetokens und die Protokollwahrscheinlichkeiten jedes im Nachrichteninhalte zurückgegebenen Ausgabetokens.
- **reasoning\_effort:** steuert das Argumentationsverhalten für Modelle, die zum Denken fähig sind. Wird **reasoning\_effort** nur gesetzt, wenn (derzeit) ein **model\_type** Modell angegeben wird, das zu Argumenten fähig ist. **amazon.nova-2-lite-v1:0:256k** Verfügbare Optionen sind **null** (Standardwert, falls nicht festgelegt; deaktiviert Argumentation), oder. **low high**

Beachten Sie, dass wir für **humaneval** die folgende Inferenzkonfiguration empfehlen:

```
inference:
 top_k: 1
 max_new_tokens: 1600
 temperature: 0.0
```

## MLflow-Konfiguration

Im Folgenden finden Sie eine MLflow-Konfiguration und eine Erläuterung der beteiligten Parameter. Alle Parameter sind optional.

```
run:
 mlflow_tracking_uri: ""
 mlflow_experiment_name: ""
 mlflow_run_name: ""
```

- **mlflow\_tracking\_uri:** (Optional) Der Standort des MLflow-Tracking-Servers (nur auf SMHP erforderlich)
- **mlflow\_experiment\_name:** (Optional) Name des Experiments zur Gruppierung verwandter ML-Läufe
- **mlflow\_run\_name:** (Optional) Benutzerdefinierter Name für einen bestimmten Trainingslauf innerhalb eines Experiments

## Beispiele für Bewertungsrezepte

Amazon Nova bietet vier Arten von Bewertungsrezepten, die im SageMaker HyperPod GitHub Rezepte-Repository verfügbar sind.

### Allgemeine Text-Benchmark-Rezepte

Diese Rezepte ermöglichen es Ihnen, die grundlegenden Funktionen von Amazon-Nova-Modellen anhand einer umfassenden Suite von reinen Text-Benchmarks zu bewerten. Sie werden im Format `xxx_general_text_benchmark_eval.yaml` bereitgestellt.

### Benchmark-Rezepte mit eigenem Datensatz

Diese Rezepte ermöglichen es Ihnen, Ihren eigenen Datensatz für das Benchmarking zu verwenden und die Modellergebnisse anhand verschiedener Arten von Metriken mit Referenzantworten zu vergleichen. Sie werden im Format `xxx_bring_your_own_dataset_eval.yaml` bereitgestellt.

Im Folgenden sind die Anforderungen für die Verwendung Ihres eigenen Datensatzes aufgeführt:

- Anforderungen an das Dateiformat
  - Sie müssen eine einzige `gen_qa.jsonl`-Datei mit Bewertungsbeispielen beifügen.
  - Ihr Datensatz muss an einen S3-Speicherort hochgeladen werden, an dem der SageMaker Schulungsjob darauf zugreifen kann.
  - Die Datei muss dem erforderlichen Schemaformat für einen allgemeinen Q&A-Datensatz entsprechen.
- Anforderungen an das Schemaformat – jede Zeile in der JSONL-Datei muss ein JSON-Objekt mit den folgenden Feldern sein:
  - `query`: (erforderlich) Zeichenfolge, die die Frage oder Anweisung enthält, für die eine Antwort erforderlich ist
  - `response`: (erforderlich) Zeichenfolge, die die erwartete Modellausgabe enthält
  - `system`: (optional) Zeichenfolge, die den System-Prompt enthält, der vor der Verarbeitung der Abfrage das Verhalten, die Rolle oder die Persönlichkeit des KI-Modells festlegt
  - `metadata`: (Optional) Zeichenfolge, die Metadaten enthält, die dem Eintrag zu Tagging-Zwecken zugeordnet sind.

Hier ein Beispieleintrag zur Verwendung des eigenen Datensatzes

```
{
```



```
"system":"You are a english major with top marks in class who likes to give minimal
word responses: ",
"query":"What is the symbol that ends the sentence as a question",
"response":"?"
}
{
 "system":"You are a pattern analysis specialist that provides succinct answers: ",
 "query":"What is the next number in this series? 1, 2, 4, 8, 16, ?",
 "response":"32"
}
{
 "system":"You have great attention to detail that follows instructions accurately:
",
 "query":"Repeat only the last two words of the following: I ate a hamburger today
and it was kind of dry",
 "response":"of dry"
}
```

Um Ihren benutzerdefinierten Datensatz zu verwenden, ändern Sie Ihr Bewertungsrezept mit den folgenden Pflichtfeldern, verändern Sie jedoch nicht den Inhalt:

```
evaluation:
 task: gen_qa
 strategy: gen_qa
 metric: all
```

Die folgenden Einschränkungen gelten:

- Pro Bewertung ist nur eine JSONL-Datei zulässig.
- Die Datei muss strikt dem definierten Schema folgen.
- Begrenzung der Kontextlänge: Für jede Stichprobe im Datensatz sollte die Kontextlänge (einschließlich System- und Abfrageaufforderungen) weniger als 3,5 KB betragen.

## Benchmark-Rezepte für Nova LLM-as-a-Judge

Amazon Nova LLM-as-a-Judge ist eine Modellbewertungsfunktion, mit der Kunden die Qualität der Antworten eines Modells mit einer Antwort aus einem Basismodell anhand eines benutzerdefinierten Datensatzes vergleichen können. Es verwendet einen Datensatz mit Eingabeaufforderungen, Basisantworten und Antworten von Herausforderern und verwendet ein Amazon Nova Judge-Modell,

um eine auf [Bradley-TerryWahrscheinlichkeit](#) basierende Winrate-Metrik mit paarweisen Vergleichen bereitzustellen.

Die Rezepte werden im Format `xxx_llm_judge_eval.yaml` bereitgestellt.

Dies sind die Anforderungen für LLM-as-a-Judge:

- Anforderungen an das Dateiformat
  - Fügen Sie eine einzige `llm_judge.jsonl`-Datei mit Bewertungsbeispielen hinzu. Der Dateiname muss `llm_judge.jsonl` lauten.
  - [Ihr Datensatz muss an einen S3-Standort hochgeladen werden, auf den AI RIG zugreifen kann. SageMaker SageMaker HyperPod](#)
  - Die Datei muss dem für den `llm_judge.jsonl`-Datensatz erforderlichen Schemaformat entsprechen.
  - Der Eingabedatensatz sollte sicherstellen, dass alle Datensätze eine Kontextlänge von weniger als 12 000 haben.
- Anforderungen an das Schemaformat – jede Zeile in der JSONL-Datei muss ein JSON-Objekt mit den folgenden Feldern sein:
  - `prompt`: (erforderlich) eine Zeichenfolge, die den Prompt für die generierte Antwort enthält
  - `response_A`: eine Zeichenfolge, die die Basisantwort enthält
  - `response_B`: eine Zeichenfolge, die die alternative Antwort enthält, die mit der Basisantwort verglichen wird

Hier ein Beispieleintrag für LLM-as-a-Judge

```
{
 "prompt": "What is the most effective way to combat climate change?",
 "response_A": "The most effective way to combat climate change is through a combination of transitioning to renewable energy sources and implementing strict carbon pricing policies. This creates economic incentives for businesses to reduce emissions while promoting clean energy adoption.",
 "response_B": "We should focus on renewable energy. Solar and wind power are good. People should drive electric cars. Companies need to pollute less."
}
{
 "prompt": "Explain how a computer's CPU works",
 "response_A": "CPU is like brain of computer. It does math and makes computer work fast. Has lots of tiny parts inside.",
```

```
"response_B": "A CPU (Central Processing Unit) functions through a fetch-execute cycle, where instructions are retrieved from memory, decoded, and executed through its arithmetic logic unit (ALU). It coordinates with cache memory and registers to process data efficiently using binary operations."
}
{
 "prompt": "How does photosynthesis work?",
 "response_A": "Plants do photosynthesis to make food. They use sunlight and water. It happens in leaves.",
 "response_B": "Photosynthesis is a complex biochemical process where plants convert light energy into chemical energy. They utilize chlorophyll to absorb sunlight, combining CO2 and water to produce glucose and oxygen through a series of chemical reactions in chloroplasts."
}
```

Um Ihren benutzerdefinierten Datensatz zu verwenden, ändern Sie Ihr Bewertungsrezept mit den folgenden Pflichtfeldern, verändern Sie jedoch nicht den Inhalt:

```
evaluation:
 task: llm_judge
 strategy: judge
 metric: all
```

Die folgenden Einschränkungen gelten:

- Pro Bewertung ist nur eine JSONL-Datei zulässig.
- Die Datei muss strikt dem definierten Schema folgen.
- Die Modelle von Amazon Nova Judge sind für die Spezifikationen aller Modellfamilien (d. h. Lite, Micro und Pro) identisch.
- Benutzerdefinierte Judge-Modelle werden derzeit nicht unterstützt.
- Begrenzung der Kontextlänge: Für jede Stichprobe im Datensatz sollte die Kontextlänge (einschließlich System- und Abfrageaufforderungen) weniger als 7 KB betragen.

## Nova LLM als Jurorin für multimodale (Bild-) Benchmark-Rezepte

Nova LLM Judge for multi-modal (Bild), kurz für Amazon Nova MM\_LLM Judge, ist eine Modellbewertungsfunktion, mit der Sie die Qualität der Antworten eines Modells anhand eines benutzerdefinierten Datensatzes mit den Antworten eines Basismodells vergleichen können. Es akzeptiert einen Datensatz, der Eingabeaufforderungen, Basisantworten und Antworten von

Herausforderern sowie Bilder in Form einer Base64-encoded Zeichenfolge enthält, und verwendet dann ein Amazon Nova Judge-Modell, um durch paarweise Vergleiche eine Gewinnraten-Metrik bereitzustellen, die auf der [Bradley-Terry](#) Wahrscheinlichkeit basiert. Rezeptformat: `xxx_mm_llm_judge_eval.yaml`.

## Anforderungen an den Nova-LLM-Datensatz

### Dateiformat:

- Eine einzige `mm_llm_judge.jsonl`-Datei mit Bewertungsbeispielen. Der Dateiname muss exakt sein. `llm_judge.jsonl`
- Sie müssen Ihren Datensatz an einen S3-Speicherort hochladen, an dem SageMaker Training Jobs darauf zugreifen kann.
- Die Datei muss dem für den `mm_llm_judge`-Datensatz erforderlichen Schemaformat entsprechen.
- Der Eingabedatensatz sollte sicherstellen, dass alle Datensätze eine Kontextlänge von weniger als 12 k haben, mit Ausnahme des Bildattributs.

Schemaformat – Jede Zeile in der `.jsonl`-Datei muss ein JSON-Objekt mit den folgenden Feldern sein.

- Pflichtfelder

`prompt`: Zeichenfolge, die den Prompt für die generierte Antwort enthält

`images`: Array, das eine Liste von Objekten mit Datenattributen enthält (Werte sind Base64-encoded Bildzeichenfolgen).

`response_A`: Zeichenfolge, die die Basisantwort enthält

`response_B`: Zeichenfolge, die die alternative Antwort enthält, die mit der Basisantwort verglichen wird

### Beispieleintrag

Aus Gründen der besseren Lesbarkeit enthält das folgende Beispiel neue Zeilen und Einrückungen, aber im eigentlichen Datensatz sollte sich jeder Datensatz in einer einzigen Zeile befinden.

```
{
```

```

"prompt": "what is in the image?",
"images": [
 {
 "data": "data:image/jpeg;base64,/9j/2wBDAAQDAwQDAwQEAwQFBAQFBgo..."
 }
],
"response_A": "a dog.",
"response_B": "a cat.",
}
{
 "prompt": "how many animals in echo of the images?",
 "images": [
 {
 "data": "data:image/jpeg;base64,/9j/2wBDAAQDAwQDAwQEAwQFBAQFBgo..."
 },
 {
 "data": "data:image/jpeg;base64,/DKEafe3gihn..."
 }
],
 "response_A": "The first image contains one cat and the second image contains one dog",
 "response_B": "The first image has one animal and the second has one animal",
}

```

Um Ihren benutzerdefinierten Datensatz zu verwenden, ändern Sie Ihr Bewertungsrezept mit den folgenden Pflichtfeldern, verändern Sie jedoch nicht den Inhalt:

```

evaluation:
 task: mm_llm_judge
 strategy: judge
 metric: all

```

## Einschränkungen

- Pro Bewertung ist nur eine .jsonl-Datei zulässig.
- Die Datei muss strikt dem definierten Schema folgen.
- Nova MM Judge-Modelle unterstützen nur Bildreferenzen.
- Die Nova MM Judge-Modelle sind in allen Amazon Nova Lite-Spezifikationen identisch.
- Benutzerdefinierte Judge-Modelle werden derzeit nicht unterstützt.
- Der Amazon S3 S3-Image-URI wird nicht unterstützt.

- Der Eingabedatensatz sollte sicherstellen, dass alle Datensätze eine Kontextlänge von weniger als 12 k haben, mit Ausnahme des Bildattributs.

## Auf Rubriken basierender Richter

Rubric Judge ist ein erweitertes LLM-as-a-judge Bewertungsmodell, das auf Amazon Nova 2.0 Lite basiert. Im Gegensatz zum [ursprünglichen Richtermodell](#), das nur Präferenzurteile ( $A > B$ ,  $B > A$  oder Unentschieden) vorsieht, generiert Rubric Judge dynamisch benutzerdefinierte Bewertungskriterien, die auf jede Aufforderung zugeschnitten sind, und weist detaillierte Bewertungen für mehrere Dimensionen zu.

Die wichtigsten Funktionen:

- Dynamische Kriteriengenerierung: Erstellt automatisch relevante Bewertungsdimensionen auf der Grundlage der Eingabeaufforderung
- Gewichtete Bewertung: Weist jedem Kriterium Wichtigkeitsgewichte zu, um dessen relative Signifikanz widerzuspiegeln
- Granulare Bewertung: Liefert detaillierte Punktzahlen auf binärer (true/false) oder Skala (1-5) Basis für jedes Kriterium
- Qualitätskennzahlen: Berechnet kontinuierliche Qualitätswerte (Skala 0-1), die das Ausmaß der Unterschiede zwischen den Antworten quantifizieren

Vom Modell generiertes Beispielkriterium:

```
price_validation:
 description: "The response includes validation to ensure price is a positive value."
 type: "scale"
 weight: 0.3
```

Das Modell bewertet beide Antworten anhand aller generierten Kriterien und verwendet dann diese Punktzahlen auf Kriterienebene als Grundlage für die endgültige Präferenzentscheidung.

## Themen

- [Konfiguration des Rezepts](#)
- [Format des Eingabedatensatzes](#)
- [Ergebnis der Bewertung](#)
- [Unterstützung von Argumentationsmodellen](#)

## Konfiguration des Rezepts

### Rezept für Rubrik Judge

Aktiviere Rubric Judge, indem `task: rubric_llm_judge` du in deinem Rezept Folgendes eingibst:

```
run:
 name: nova-eval-job-name # [MODIFIABLE] Unique
 identifier for your evaluation job
 model_type: amazon.nova-2-lite-v1:0:256k # [FIXED] Rubric Judge model
 type
 model_name_or_path: "nova-lite-2/prod" # [FIXED] Path to model
 checkpoint or identifier
 replicas: 1 # [MODIFIABLE] Number of
 replicas for SageMaker Training job
 data_s3_path: "" # [FIXED] Leave empty for
 SageMaker Training job
 output_s3_path: "" # [FIXED] Leave empty for
 SageMaker Training job

evaluation:
 task: rubric_llm_judge # [FIXED] Evaluation task -
 enables Rubric Judge
 strategy: judge # [FIXED] Evaluation strategy
 metric: all # [FIXED] Metric calculation
 method

inference:
 max_new_tokens: 12000 # [MODIFIABLE] Maximum tokens
 to generate
 top_k: -1 # [MODIFIABLE] Top-k sampling
 parameter
 top_p: 1.0 # [MODIFIABLE] Nucleus sampling
 parameter
 temperature: 0 # [MODIFIABLE] Sampling
 temperature (0 = deterministic)
```

### Originalrezept für LLM als Judge (zum Vergleich)

Das ursprüngliche Richtermodell verwendet `task: llm_judge`:

```
run:
```

```

name: eval-job-name # [MODIFIABLE] Unique
identifier for your evaluation job
model_type: amazon.nova-micro-v1:0:128k # [FIXED] Model type
model_name_or_path: "nova-micro/prod" # [FIXED] Path to model
checkpoint or identifier
replicas: 1 # [MODIFIABLE] Number of
replicas for SageMaker Training job
data_s3_path: "" # [FIXED] Leave empty for
SageMaker Training job
output_s3_path: "" # [FIXED] Leave empty for
SageMaker Training job

evaluation:
 task: llm_judge # [FIXED] Original judge task
 strategy: judge # [FIXED] Evaluation strategy
 metric: all # [FIXED] Metric calculation
 method

inference:
 max_new_tokens: 12000 # [MODIFIABLE] Maximum tokens
 to generate
 top_k: -1 # [MODIFIABLE] Top-k sampling
 parameter
 top_p: 1.0 # [MODIFIABLE] Nucleus sampling
 parameter
 temperature: 0 # [MODIFIABLE] Sampling
 temperature (0 = deterministic)

```

## Format des Eingabedatensatzes

Das Format des Eingabedatensatzes ist identisch mit dem [ursprünglichen Richtermodell](#):

Erforderliche Felder:

- **prompt**: Zeichenfolge, die die Eingabeaufforderung und Anweisungen enthält
- **response\_A**: Zeichenfolge, die die Ausgabe des Basismodells enthält
- **response\_B**: Zeichenfolge, die die benutzerdefinierte Modellausgabe enthält

Beispieldatensatz (JSONL-Format):

```

{"prompt": "What is the most effective way to combat climate change?", "response_A":
 "The most effective way to combat climate change is through a combination of

```



transitioning to renewable energy sources and implementing strict carbon pricing policies. This creates economic incentives for businesses to reduce emissions while promoting clean energy adoption.", "response\_B": "We should focus on renewable energy. Solar and wind power are good. People should drive electric cars. Companies need to pollute less."}

{"prompt": "Explain how a computer's CPU works", "response\_A": "CPU is like brain of computer. It does math and makes computer work fast. Has lots of tiny parts inside.", "response\_B": "A CPU (Central Processing Unit) functions through a fetch-execute cycle, where instructions are retrieved from memory, decoded, and executed through its arithmetic logic unit (ALU). It coordinates with cache memory and registers to process data efficiently using binary operations."}

{"prompt": "How does photosynthesis work?", "response\_A": "Plants do photosynthesis to make food. They use sunlight and water. It happens in leaves.", "response\_B": "Photosynthesis is a complex biochemical process where plants convert light energy into chemical energy. They utilize chlorophyll to absorb sunlight, combining CO2 and water to produce glucose and oxygen through a series of chemical reactions in chloroplasts."}

### Anforderungen an das Format:

- Jeder Eintrag muss ein einzeliliges JSON-Objekt sein
- Trennen Sie Einträge durch Zeilenumbrüche
- Folgen Sie der genauen Feldbenennung, wie in den Beispielen gezeigt

### Ergebnis der Bewertung

### Struktur der Ausgabe

Rubric Judge bietet im Vergleich zum ursprünglichen Richtermodell verbesserte Bewertungskennzahlen:

```
{
 "config_general": {
 "lighteval_sha": "string",
 "num_fewshot_seeds": "int",
 "max_samples": "int | null",
 "job_id": "int",
 "start_time": "float",
 "end_time": "float",
 "total_evaluation_time_seconds": "string",
 "model_name": "string",
 "model_sha": "string",
```

```

 "model_dtype": "string | null",
 "model_size": "string"
 },
 "results": {
 "custom|rubric_llm_judge_judge|0": {
 "a_scores": "float",
 "a_scores_stderr": "float",
 "b_scores": "float",
 "b_scores_stderr": "float",
 "ties": "float",
 "ties_stderr": "float",
 "inference_error": "float",
 "inference_error_stderr": "float",
 "score": "float",
 "score_stderr": "float",
 "weighted_score_A": "float",
 "weighted_score_A_stderr": "float",
 "weighted_score_B": "float",
 "weighted_score_B_stderr": "float",
 "score_margin": "float",
 "score_margin_stderr": "float",
 "winrate": "float",
 "lower_rate": "float",
 "upper_rate": "float"
 }
 },
 "versions": {
 "custom|rubric_llm_judge_judge|0": "int"
 }
}

```

## Neue Metriken in Rubrik Judge

Die folgenden sechs Kennzahlen sind einzigartig für Rubrik Judge und ermöglichen eine detaillierte Qualitätsbeurteilung:

| Metrik           | Description                                                                                                                                                                             |
|------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Weighted_Score_A | Durchschnittlicher normalisierter Qualitätsfaktor für Response_A für alle modellgenerierten Bewertungskriterien. Die Ergebnisse werden nach der Wichtigkeit der Kriterien gewichtet und |

| Metrik                  | Description                                                                                                                                                                                                                                                |
|-------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
|                         | auf eine Skala von 0 bis 1 normalisiert (höher = bessere Qualität)                                                                                                                                                                                         |
| Weighted_Score_A_StdErr | Standardfehler des Mittelwerts für Weighted_Score_A, was auf statistische Unsicherheit hinweist                                                                                                                                                            |
| Weighted_Score_B        | Durchschnittlicher normalisierter Qualitätsfaktor für Response_B für alle modellgenerierten Bewertungskriterien. Die Ergebnisse werden nach der Wichtigkeit der Kriterien gewichtet und auf eine Skala von 0 bis 1 normalisiert (höher = bessere Qualität) |
| Weighted_Score_B_StdErr | Standardfehler des Mittelwerts für Weighted_Score_B, was auf statistische Unsicherheit hinweist                                                                                                                                                            |
| score_margin            | Unterschied zwischen gewichteten Ergebnissen (berechnet als Weighted_Score_A — Weighted_Score_B). Bereich: -1,0 bis 1,0. Positiv = Antwort_A ist besser; negativ = Antwort_B ist besser; nahe Null = ähnliche Qualität                                     |
| score_margin_stderr     | Standardfehler des Mittelwerts für score_margin, was auf eine Unsicherheit bei der Messung von Qualitätsunterschieden hinweist                                                                                                                             |

## Grundlegendes zu Kennzahlen mit gewichteten Werten

Zweck: Gewichtete Werte ermöglichen kontinuierliche Qualitätsmessungen, die binäre Präferenzurteile ergänzen und so tiefere Einblicke in die Modellleistung ermöglichen.

Wesentliche Unterschiede zum ursprünglichen Richter:

- Ursprünglicher Richter: Gibt nur diskrete Präferenzen aus ( $A > B$ ,  $B > A$ ,  $A = B$ )

- Rubrik Judge: Gibt sowohl Präferenzen als auch kontinuierliche Qualitätswerte (Skala 0-1) auf der Grundlage benutzerdefinierter Kriterien aus

Interpretation von `score_margin`:

- `score_margin = -0.128`: Response\_B erzielte 12,8 Prozentpunkte mehr als Response\_A
- `|score_margin| < 0.1`: Geringer Qualitätsunterschied (knappe Entscheidung)
- `|score_margin| > 0.2`: Deutlicher Qualitätsunterschied (sichere Entscheidung)

Anwendungsfälle:

- Modellverbesserung: Identifizieren Sie bestimmte Bereiche, in denen Ihr Modell unterdurchschnittlich abschneidet
- Quantifizierung der Qualität: Messen Sie das Ausmaß von Leistungslücken, nicht nur Kennzahlen win/loss
- Vertrauensbeurteilung: Unterscheiden Sie zwischen knappen Entscheidungen und deutlichen Qualitätsunterschieden

#### Important

Endgültige Urteile basieren immer noch auf den ausdrücklichen Präferenzbezeichnungen des Richtermodells, um eine ganzheitliche Argumentation zu wahren und eine angemessene Abmilderung von Positionsverzerrungen durch Bewertung sicherzustellen. forward/backward Gewichtete Punktzahlen dienen als Instrumente zur Beobachtung und nicht als Ersatz für das erste Urteil.

Berechnungsmethodik

Gewichtete Werte werden nach dem folgenden Verfahren berechnet:

- Kriteriendaten extrahieren: Analysieren Sie die YAML-Ausgabe des Richters, um die Punktzahlen und Gewichtungen der Kriterien zu extrahieren
- Punktzahlen normalisieren:
  - Scale-type Kriterien (1-5): Durch Berechnung auf 0-1 normalisieren (`score - 1`) / 4
  - Binäre Kriterien (true/false): In 1 umwandeln. 0/0.0

- Gewichtungen anwenden: Multiplizieren Sie jedes normalisierte Ergebnis mit der Gewichtung des Kriteriums
- Aggregieren: Summieren Sie alle gewichteten Werte für jede Antwort
- Marge berechnen: Berechne `score_margin = weighted_score_A - weighted_score_B`

Beispiel: Wenn `Antworte_A` eine gewichtete Summe von 0,65 und `Antworte_B` eine gewichtete Summe von 0,78 hat, `score_margin` wäre das -0,13, was bedeutet, dass `Antworte_B` bei allen gewichteten Kriterien eine um 13 Prozentpunkte höhere Qualität aufweist.

## Unterstützung von Argumentationsmodellen

Die Unterstützung von Argumentationsmodellen ermöglicht die Bewertung anhand von Amazon Nova-Modellen, die explizite interne Überlegungen durchführen, bevor endgültige Antworten generiert werden. Diese Funktion nutzt die API-level Steuerung über den `reasoning_effort` Parameter, um die Argumentationsfunktion dynamisch zu aktivieren oder zu deaktivieren, wodurch möglicherweise die Antwortqualität bei komplexen Analyseaufgaben verbessert wird.

### Unterstützte Modelle:

- `amazon.nova-2-lite-v 1:0:256 k`

## Konfiguration des Rezepts

Ermöglichen Sie die Argumentation, indem Sie den `reasoning_effort` Parameter zum `inference` Abschnitt Ihres Rezepts hinzufügen:

```
run:
 name: eval-job-name # [MODIFIABLE] Unique
 identifier for your evaluation job
 model_type: amazon.nova-2-lite-v1:0:256k # [FIXED] Must be a reasoning-
supported model
 model_name_or_path: nova-lite-2/prod # [FIXED] Path to model
checkpoint or identifier
 replicas: 1 # [MODIFIABLE] Number of
replicas for SageMaker Training job
 data_s3_path: "" # [MODIFIABLE] Leave empty for
SageMaker Training job; optional for SageMaker SageMaker HyperPod job
 output_s3_path: "" # [MODIFIABLE] Output path for
SageMaker SageMaker HyperPod job (not compatible with SageMaker Training jobs)
```

```

evaluation:
 task: mmlu # [MODIFIABLE] Evaluation task
 strategy: generate # [MODIFIABLE] Evaluation
 strategy
 metric: all # [MODIFIABLE] Metric
 calculation method

inference:
 reasoning_effort: high # [MODIFIABLE] Enables
reasoning mode; options: low/medium/high or null to disable
 max_new_tokens: 200 # [MODIFIABLE] Maximum tokens
to generate
 top_k: 50 # [MODIFIABLE] Top-k sampling
parameter
 top_p: 1.0 # [MODIFIABLE] Nucleus
sampling parameter
 temperature: 0 # [MODIFIABLE] Sampling
temperature (0 = deterministic)

```

Verwenden Sie den Parameter `reasoning_effort`

Der `reasoning_effort` Parameter steuert das Argumentationsverhalten für Modelle, die zur Argumentation fähig sind.

Voraussetzungen:

- **Modellkompatibilität:** Wird `reasoning_effort` nur gesetzt, wenn (derzeit) ein Modell `model_type` angegeben wird, das zu Argumenten fähig ist `amazon.nova-2-lite-v1:0:256k`
- **Fehlerbehandlung:** Die Verwendung `reasoning_effort` mit nicht unterstützten Modellen schlägt fehl mit `ConfigValidationError: "Reasoning mode is enabled but model '{model_type}' does not support reasoning. Please use a reasoning-capable model or disable reasoning mode."`

Verfügbare Optionen:

| Option          | Behavior                             | Token-Limit | Anwendungsfall                                         |
|-----------------|--------------------------------------|-------------|--------------------------------------------------------|
| null (Standard) | Deaktiviert den Argumentationsmoduls | N/A         | Standardauswertung ohne Mehraufwand beim Argumentieren |

| Option | Behavior                                      | Token-Limit                               | Anwendungsfall                                                                                            |
|--------|-----------------------------------------------|-------------------------------------------|-----------------------------------------------------------------------------------------------------------|
| low    | Ermöglicht Argumentation mit Einschränkungen  | 4.000 Tokens für internes Denken          | Szenarien, die eine präzise Argumentation erfordern; optimiert im Hinblick auf Geschwindigkeit und Kosten |
| high   | Ermöglicht Argumentation ohne Einschränkungen | Keine Tokenbegrenzung für internes Denken | Komplexe Probleme, die eine umfassende Analyse und eine schrittweise Argumentation erfordern              |

Wann soll das Denken aktiviert werden

Verwenden Sie den Argumentationsmodus (**low**, **medium**, oder **high**) für:

- Komplexe Problemlösungsaufgaben (Mathematik, Logikrätsel, Programmieren)
- Multi-step analytische Fragen, die eine gründliche Argumentation erfordern
- Aufgaben, bei denen detaillierte Erklärungen oder schrittweises Denken die Genauigkeit verbessern
- Szenarien, in denen die Qualität der Antworten Vorrang vor der Geschwindigkeit hat

Verwenden Sie den Modus ohne Argumentation (Parameter auslassen) für:

- Einfache Fragen und Antworten oder sachliche Fragen
- Kreative Schreibaufgaben
- Wenn schnellere Reaktionszeiten entscheidend sind
- Leistungsbenchmarking, bei dem der Argumentationsaufwand ausgeschlossen werden sollte
- Kostenoptimierung, wenn Argumentation die Aufgabenleistung nicht verbessert

Fehlerbehebung

Fehler: „Der Argumentationsmodus ist aktiviert, aber das Modell unterstützt kein Argumentieren“

Ursache: Der `reasoning_effort` Parameter ist auf einen Wert ungleich Null gesetzt, aber der angegebene Wert unterstützt `model_type` keine Argumentation.

### Auflösung

- Stellen Sie sicher, dass Ihr Modelltyp `amazon.nova-2-lite-v1:0:256k`
- Wenn Sie ein anderes Modell verwenden, wechseln Sie entweder zu einem Modell, das vernünftiges Denken ermöglicht, oder entfernen Sie den `reasoning_effort` Parameter aus Ihrem Rezept

## Starten eines Bewertungsjobs

Im Folgenden finden Sie einen Vorschlag für die Konfiguration des Bewertungs-Instance-Typs und des Modelltyps:

```
Install Dependencies (Helm - https://helm.sh/docs/intro/install/)
curl -fsSL -o get_helm.sh https://raw.githubusercontent.com/helm/helm/main/scripts/get-helm-3
chmod 700 get_helm.sh
./get_helm.sh
rm -f ./get_helm.sh

Install the SageMaker HyperPod CLI
git clone --recurse-submodules https://github.com/aws/sagemaker-hyperpod-cli.git
git checkout -b release_v2
cd sagemaker-hyperpod-cli
pip install .

Verify the installation
hyperpod --help

Connect to a SageMaker HyperPod Cluster
hyperpod connect-cluster --cluster-name cluster-name

Submit the Job using the recipe for eval
Namespace by default should be kubeflow
hyperpod start-job [--namespace namespace] --recipe evaluation/nova/
nova_micro_p5_48x1_general_text_benchmark_eval --override-parameters \
```



```
'{
 "instance_type": "p5d.48xlarge",
 "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-
HP-Eval-V2-latest",
 "recipes.run.name": custom-run-name,
 "recipes.run.model_type": model_type,
 "recipes.run.model_name_or_path": "model name or finetune checkpoint s3uri",
 "recipes.run.data_s3_path": "s3 for input data only for genqa and llm_judge, must be
full S3 path that include filename",
}'

List jobs
hyperpod list-jobs [--namespace namespace] [--all-namespaces]

Getting Job details
hyperpod get-job --job-name job-name [--namespace namespace] [--verbose]

Listing Pods
hyperpod list-pods --job-name job-name --namespace namespace

Cancel Job
hyperpod cancel-job --job-name job-name [--namespace namespace]
```

Sie sollten den Jobstatus auch über die Konsole des Amazon-EKS-Clusters einsehen können.

## Zugriff auf und Analyse der Bewertungsergebnisse

Nachdem Ihr Bewertungsjob erfolgreich abgeschlossen wurde, können Sie mithilfe der Informationen in diesem Abschnitt auf die Ergebnisse zugreifen und sie analysieren. Basierend auf dem im Rezept definierten `output_s3_path` (wie `s3://output_path/`) sieht die Ausgabestruktur wie folgt aus:

```
job_name/
eval-result/
results_[timestamp].json
inference_output.jsonl (only present for gen_qa)
details/
model/
execution-date-time/
details_task_name_#_datetime.parquet
tensorboard-results/
 ### eval/
 ### events.out.tfevents.[timestamp]
```

Die Metrikergebnisse werden am angegebenen S3-Ausgabespeicherort `s3://output_path/job_name/eval-result/result-timestamp.json` gespeichert.

Tensorboard-Ergebnisse werden im S3-Pfad `s3://output_path/job_name/eval-tensorboard-result/eval/event.out.tfevents.epoch+ip` gespeichert.

Alle Inferenzausgaben, mit Ausnahme von `llm_judge` und `strong_reject`, werden im S3-Pfad gespeichert: `s3://output_path/job_name/eval-result/details/model/taskname.parquet`.

Für `gen_qa` enthält die Datei `inference_output.jsonl` die folgenden Felder für jedes JSON-Objekt:

- Prompt – der letzte Prompt, der an das Modell gesendet wurde
- Inferenz – die unformatierte Inferenzausgabe des Modells
- gold — Die Zielantwort aus dem Eingabedatensatz
- metadata — Die Metadatenzeichenfolge aus dem Eingabedatensatz, falls angegeben

Führen Sie die folgenden Schritte aus, um Ihre Bewertungskennzahlen in Tensorboard zu visualisieren:

1. Navigieren Sie zu SageMaker AI Tensorboard.
2. Wählen Sie S3-Ordner aus.
3. Fügen Sie Ihren S3-Ordnerpfad hinzu, z. B. `s3://output_path/job-name/eval-tensorboard-result/eval`.
4. Warten Sie, bis die Synchronisation abgeschlossen ist.

Die Zeitreihen, Skalare und Textvisualisierungen sind verfügbar.

Wir empfehlen Ihnen, die folgenden bewährten Methoden:

- Organisieren Sie Ihre Ausgabepfade nach Modell und Benchmark-Typ.
- Halten Sie konsistente Namenskonventionen ein, um die Nachverfolgung zu vereinfachen.
- Speichern Sie die extrahierten Ergebnisse an einem sicheren Ort.
- Überwachen Sie den TensorBoard Synchronisierungsstatus für ein erfolgreiches Laden der Daten.

Sie finden SageMaker HyperPod Auftragsfehlerprotokolle in der CloudWatch Protokollgruppe `/aws/sagemaker/Clusters/cluster-id`.

### Ausgabeformat für Log Probability

Wenn `top_logprobs` es in Ihren Inferenzeinstellungen konfiguriert ist, enthält die Evaluationsausgabe Protokollwahrscheinlichkeiten auf Tokenebene in den Parquet-Dateien. Jede Token-Position enthält ein Wörterbuch der wichtigsten Token-Kandidaten mit ihren Log-Wahrscheinlichkeiten in der folgenden Struktur:

```
{
 "Ġint": {"logprob_value": -17.8125, "decoded_value": " int"},
 "Ġthe": {"logprob_value": -2.345, "decoded_value": " the"}
}
```

Jeder Token-Eintrag enthält:

- `logprob_value`: Der Log-Wahrscheinlichkeitswert für das Token
- `decoded_value`: Die menschenlesbare dekodierte Zeichenkettendarstellung des Tokens

Das rohe Tokenizer-Token wird als Wörterbuchschlüssel verwendet, um die Einzigartigkeit zu gewährleisten und bietet gleichzeitig eine lesbare Interpretation. `decoded_value`

### RFT-Bewertung

#### Note

Die Evaluierung über Remote-Prämienfunktionen in Ihrer eigenen AWS Umgebung ist nur verfügbar, wenn Sie Kunde von Amazon Nova Forge sind.

#### Important

Das `rl_env` Konfigurationsfeld wird ausschließlich zur Evaluierung verwendet, nicht für Schulungen. Während des Trainings konfigurieren Sie Belohnungsfunktionen mithilfe einer `reward_lambda_arn` (Single-Turn) oder einer BYOO-Infrastruktur mit `rollout.delegate: true` (Multi-Turn).

## Was ist RFT-Evaluierung?

Mit der RFT-Evaluierung können Sie die Leistung Ihres Modells mithilfe benutzerdefinierter Belohnungsfunktionen vor, während oder nach dem Reinforcement-Learning-Training bewerten. Im Gegensatz zu Standardbewertungen, die vordefinierte Metriken verwenden, können Sie mit RFT Evaluation Ihre eigenen Erfolgskriterien mithilfe einer Lambda-Funktion definieren, die Modellergebnisse auf der Grundlage Ihrer spezifischen Anforderungen bewertet.

## Warum mit RFT evaluieren?

Die Bewertung ist entscheidend, um festzustellen, ob der RL-Feinabstimmungsprozess Folgendes beinhaltet:

- Verbesserte Abstimmung des Modells auf Ihren spezifischen Anwendungsfall und Ihre menschlichen Werte
- Beibehaltung oder Verbesserung der Modellfunktionen bei wichtigen Aufgaben
- Vermeidung unbeabsichtigter Nebenwirkungen wie verringerte Sachlichkeit, erhöhte Ausführlichkeit oder Leistungseinbußen bei anderen Aufgaben
- Hat Ihre benutzerdefinierten Erfolgskriterien erfüllt, wie sie in Ihrer Belohnungsfunktion definiert sind

## Wann sollte die RFT-Evaluierung verwendet werden

Verwenden Sie RFT Evaluation in diesen Szenarien:

- Vor dem RFT-Training: Legen Sie Basiskennzahlen für Ihren Bewertungsdatensatz fest
- Während des RFT-Trainings: Überwachen Sie den Trainingsfortschritt mit Zwischenstationen
- Nach dem RFT-Training: Stellen Sie sicher, dass das endgültige Modell Ihren Anforderungen entspricht
- Modelle vergleichen: Evaluieren Sie mehrere Modellversionen anhand einheitlicher Prämienkriterien

 Note

Verwenden Sie RFT Evaluation, wenn Sie benutzerdefinierte, domänenspezifische Metriken benötigen. Verwenden Sie für allgemeine Bewertungsmethoden (Genauigkeit, Verwirrung, BLEU) die Standardauswertungsmethoden.

## Themen

- [Datenformatanforderungen](#)
- [Vorbereitung Ihres Bewertungsrezepts](#)
- [Voreingestellte Belohnungsfunktionen](#)
- [Erstellen Sie Ihre Belohnungsfunktion](#)
- [IAM-Berechtigungen](#)
- [Ausführung des Evaluierungsjobs](#)
- [Evaluierungsergebnisse verstehen](#)

## Datenformatanforderungen

### Struktur der Eingabedaten

Die Eingabedaten für die RFT-Auswertung müssen dem OpenAI Fine-Tuning Reinforcement-Format entsprechen. Jedes Beispiel ist ein JSON-Objekt, das Folgendes enthält:

- `messages`: Eine Reihe von Konversationswechseln mit `system` und Rollen `user`
- Optionale weitere Metadaten, z. B. `reference_answer`

### Beispiel für ein Datenformat

Das folgende Beispiel zeigt das erforderliche Format:

```
{
 "messages": [
 {
 "role": "user",
 "content": [
 {
 "type": "text",
```

```

 "text": "Solve for x. Return only JSON like {\"x\": <number>}. Equation: 2x +
5 = 13"
 }
]
}
],
"reference_answer": {
 "x": 4
}
}

```

## Aktuelle Einschränkungen

Für die RFT-Evaluierung gelten die folgenden Einschränkungen:

- Nur Text: Es werden keine multimodalen Eingaben (Bilder, Audio, Video) unterstützt
- Single-turn Konversationen: Unterstützt nur Einzelbenutzernachrichten (keine Multi-Turn-Dialoge)
- JSON-Format: Die Eingabedaten müssen im JSONL-Format vorliegen (ein JSON-Objekt pro Zeile)
- Modellausgaben: Die Auswertung erfolgt anhand der generierten Vervollständigungen aus dem angegebenen Modell

## Vorbereitung Ihres Bewertungsrezepts

### Beispiel für eine Rezeptkonfiguration

Das folgende Beispiel zeigt ein vollständiges RFT-Evaluierungsrezept:

```

run:
 name: nova-lite-rft-eval-job
 model_type: amazon.nova-lite-v1:0:300k
 model_name_or_path: s3://escrow_bucket/model_location # [MODIFIABLE] S3 path to
your model or model identifier
 replicas: 1 # [MODIFIABLE] For SageMaker
Training jobs only; fixed for SageMaker HyperPod jobs
 data_s3_path: "" # [REQUIRED FOR HYPERPOD]
Leave empty for SageMaker Training jobs
 output_s3_path: "" # [REQUIRED] Output artifact
S3 path for evaluation results

evaluation:
 task: rft_eval # [FIXED] Do not modify

```

```

strategy: rft_eval # [FIXED] Do not modify
metric: all # [FIXED] Do not modify

Inference Configuration
inference:
 max_new_tokens: 8196 # [MODIFIABLE] Maximum tokens
 to generate
 top_k: -1 # [MODIFIABLE] Top-k sampling
 parameter
 top_p: 1.0 # [MODIFIABLE] Nucleus
 sampling parameter
 temperature: 0 # [MODIFIABLE] Sampling
 temperature (0 = deterministic)
 top_logprobs: 0

Evaluation Environment Configuration (NOT used in training)
rl_env:
 reward_lambda_arn: arn:aws:lambda:<region>:<account_id>:function:<reward-function-name>

```

## Voreingestellte Belohnungsfunktionen

Zwei voreingestellte Belohnungsfunktionen (`prime_code` und `prime_math`) sind als Lambda-Schicht für eine einfache Integration in Ihre RFT-Lambda-Funktionen verfügbar.

### -Übersicht

Diese voreingestellten Funktionen bieten sofort einsatzbereite Evaluierungsfunktionen für:

- `prime_code`: Codegenerierung und Korrektheitsbewertung
- `prime_math`: Mathematisches Denken und Bewertung der Problemlösung

### Quick Setup

Um voreingestellte Belohnungsfunktionen zu verwenden:

1. Laden Sie die Lambda-Schicht aus den [nova-custom-eval-sdk-Versionen](#) herunter
2. Veröffentlichen Sie die Lambda-Schicht mit AWS CLI:

```

aws lambda publish-layer-version \
 --layer-name preset-function-layer \
 --description "Preset reward function layer with dependencies" \

```

```
--zip-file fileb://universal_reward_layer.zip \
--compatible-runtimes python3.9 python3.10 python3.11 python3.12 \
--compatible-architectures x86_64 arm64
```

3. Fügen Sie die Ebene zu Ihrer Lambda-Funktion in der AWS Konsole hinzu (Wählen Sie die Voreinstellungsfunktionsebene aus der benutzerdefinierten Ebene aus und fügen Sie sie auch für Numpy-Abhängigkeiten hinzu) AWSSDKPandas-Python312
4. Importieren und in Ihrem Lambda-Code verwenden:

```
from prime_code import compute_score # For code evaluation
from prime_math import compute_score # For math evaluation
```

### prime\_code-Funktion

Zweck: Evaluiert Aufgaben zur Python-Codegenerierung, indem Code anhand von Testfällen ausgeführt und die Richtigkeit gemessen wird.

Beispiel für ein Eingabedatensatzformat aus der Auswertung:

```
{"messages":[{"role":"user","content":"Write a function that returns the sum of
two numbers."}], "reference_answer":{"inputs":["3\n5", "10\n-2", "0\n0"], "outputs":
["8", "8", "0"]}}
{"messages":[{"role":"user","content":"Write a function to check if a number
is even."}], "reference_answer":{"inputs":["4", "7", "0", "-2"], "outputs":
["True", "False", "True", "True"]}}
```

### Hauptmerkmale:

- Automatische Codeextraktion aus Markdown-Codeblöcken
- Funktionserkennung und anrufbasiertes Testen
- Ausführung von Testfällen mit Timeout-Schutz
- Syntaxvalidierung und Kompilierungsprüfungen
- Detaillierte Fehlerberichterstattung mit Tracebacks

### prime\_math-Funktion

Zweck: Evaluiert die Fähigkeiten zum mathematischen Denken und zur Problemlösung mit Unterstützung symbolischer Mathematik.



## Eingabeformat:

```
{"messages":[{"role":"user","content":"What is the derivative of x^2 + 3x?."}], "reference_answer":"2*x + 3"}
```

## Die wichtigsten Funktionen:

- Symbolische mathematische Bewertung mit SymPy
- Mehrere Antwortformate (LaTeX, Klartext, symbolisch)
- Mathematische Äquivalenzprüfung
- Normalisierung und Vereinfachung von Ausdrücken

## Best Practices

Folgen Sie diesen bewährten Methoden, wenn Sie voreingestellte Belohnungsfunktionen verwenden:

- Verwenden Sie in Testfällen die richtigen Datentypen (Ganzzahlen im Vergleich zu Zeichenketten, boolesche Werte im Vergleich zu „True“)
- Sorgen Sie bei Codeproblemen für klare Funktionssignaturen
- Schließen Sie Grenzfälle in Testeingaben ein (Null, negative Zahlen, leere Eingaben)
- Formatieren Sie mathematische Ausdrücke konsistent in Referenzantworten
- Testen Sie Ihre Belohnungsfunktion vor der Bereitstellung mit Beispieldaten

## Erstellen Sie Ihre Belohnungsfunktion

### Lambda-ARN

Sie müssen sich für den Lambda-ARN auf das folgende Format beziehen:

```
"arn:aws:lambda:*:*:function:*SageMaker*"
```

Wenn das Lambda dieses Benennungsschema nicht hat, schlägt der Job mit dem folgenden Fehler fehl:

```
[ERROR] Unexpected error: lambda_arn must contain one of: ['SageMaker', 'sagemaker', 'Sagemaker'] when running on SMHP platform (Key: lambda_arn)
```

## Struktur der Lambda-Funktion

Ihre Lambda-Funktion empfängt Stapel von Modellausgaben und gibt Prämienwerte zurück. Im Folgenden finden Sie ein Beispiel für eine Implementierung:

```
from typing import List, Any
import json
import re
from dataclasses import asdict, dataclass

@dataclass
class MetricResult:
 """Individual metric result."""
 name: str
 value: float
 type: str

@dataclass
class RewardOutput:
 """Reward service output."""
 id: str
 aggregate_reward_score: float
 metrics_list: List[MetricResult]

def lambda_handler(event, context):
 """ Main lambda handler """
 return lambda_grader(event)

def lambda_grader(samples: list[dict]) -> list[dict]:
 """ Core grader function """
 scores: List[RewardOutput] = []

 for sample in samples:
 print("Sample: ", json.dumps(sample, indent=2))

 # Extract components
 idx = sample.get("id", "no id")
 if not idx or idx == "no id":
 print(f"ID is None/empty for sample: {sample}")

 ground_truth = sample.get("reference_answer")
```

```
if "messages" not in sample:
 print(f"Messages is None/empty for id: {idx}")
 continue

if ground_truth is None:
 print(f"No answer found in ground truth for id: {idx}")
 continue

Get model's response (last turn is assistant turn)
last_message = sample["messages"][-1]

if last_message["role"] != "nova_assistant":
 print(f"Last message is not from assistant for id: {idx}")
 continue

if "content" not in last_message:
 print(f"Completion text is empty for id: {idx}")
 continue

model_text = last_message["content"]

--- Actual scoring logic (lexical overlap) ---
ground_truth_text = _extract_ground_truth_text(ground_truth)

Calculate main score and individual metrics
overlap_score = _lexical_overlap_score(model_text, ground_truth_text)

Create two separate metrics as in the first implementation
accuracy_score = overlap_score # Use overlap as accuracy
fluency_score = _calculate_fluency(model_text) # New function for fluency

Create individual metrics
metrics_list = [
 MetricResult(name="accuracy", value=accuracy_score, type="Metric"),
 MetricResult(name="fluency", value=fluency_score, type="Reward")
]

ro = RewardOutput(
 id=idx,
 aggregate_reward_score=overlap_score,
 metrics_list=metrics_list
)
```

```

 print(f"Response for id: {idx} is {ro}")
 scores.append(ro)

Convert to dict format
result = []
for score in scores:
 result.append({
 "id": score.id,
 "aggregate_reward_score": score.aggregate_reward_score,
 "metrics_list": [asdict(metric) for metric in score.metrics_list]
 })

return result

def _extract_ground_truth_text(ground_truth: Any) -> str:
 """
 Turn the `ground_truth` field into a plain string.
 """
 if isinstance(ground_truth, str):
 return ground_truth

 if isinstance(ground_truth, dict):
 # Common patterns: { "explanation": "...", "answer": "..." }
 if "explanation" in ground_truth and isinstance(ground_truth["explanation"],
str):
 return ground_truth["explanation"]
 if "answer" in ground_truth and isinstance(ground_truth["answer"], str):
 return ground_truth["answer"]
 # Fallback: stringify the whole dict
 return json.dumps(ground_truth, ensure_ascii=False)

 # Fallback: stringify anything else
 return str(ground_truth)

def _tokenize(text: str) -> List[str]:
 # Very simple tokenizer: lowercase + alphanumeric word chunks
 return re.findall(r"\w+", text.lower())

def _lexical_overlap_score(model_text: str, ground_truth_text: str) -> float:
 """
 Simple lexical overlap score in [0, 1]:

```

```

 score = |tokens(model) # tokens(gt)| / |tokens(gt)|
 """
 gt_tokens = _tokenize(ground_truth_text)
 model_tokens = _tokenize(model_text)

 if not gt_tokens:
 return 0.0

 gt_set = set(gt_tokens)
 model_set = set(model_tokens)
 common = gt_set & model_set

 return len(common) / len(gt_set)

def _calculate_fluency(text: str) -> float:
 """
 Calculate a simple fluency score based on:
 - Average word length
 - Text length
 - Sentence structure

 Returns a score between 0 and 1.
 """
 # Simple implementation - could be enhanced with more sophisticated NLP
 words = _tokenize(text)

 if not words:
 return 0.0

 # Average word length normalized to [0,1] range
 # Assumption: average English word is ~5 chars, so normalize around that
 avg_word_len = sum(len(word) for word in words) / len(words)
 word_len_score = min(avg_word_len / 10, 1.0)

 # Text length score - favor reasonable length responses
 ideal_length = 100 # words
 length_score = min(len(words) / ideal_length, 1.0)

 # Simple sentence structure check (periods, question marks, etc.)
 sentence_count = len(re.findall(r'[.!?]+', text)) + 1
 sentence_ratio = min(sentence_count / (len(words) / 15), 1.0)

 # Combine scores

```

```
fluency_score = (word_len_score + length_score + sentence_ratio) / 3

return fluency_score
```

## Lambda-Anforderungsformat

Ihre Lambda-Funktion empfängt Daten in diesem Format:

```
[
 {
 "id": "sample-001",
 "messages": [
 {
 "role": "user",
 "content": [
 {
 "type": "text",
 "text": "Do you have a dedicated security team?"
 }
]
 },
 {
 "role": "nova_assistant",
 "content": [
 {
 "type": "text",
 "text": "As an AI developed by Company, I don't have a dedicated security team in the traditional sense. However, the development and deployment of AI systems like me involve extensive security measures, including data encryption, user privacy protection, and other safeguards to ensure safe and responsible use."
 }
]
 }
],
 "reference_answer": {
 "compliant": "No",
 "explanation": "As an AI developed by Company, I do not have a traditional security team. However, the deployment involves stringent safety measures, such as encryption and privacy safeguards."
 }
 }
]
```

 Note

Die Nachrichtenstruktur umfasst das verschachtelte content Array, das dem Eingabedatenformat entspricht. Die letzte Nachricht mit Rolle nova\_assistant enthält die vom Modell generierte Antwort.

## Lambda-Antwortformat

Ihre Lambda-Funktion muss Daten in diesem Format zurückgeben:

```
[
 {
 "id": "sample-001",
 "aggregate_reward_score": 0.75,
 "metrics_list": [
 {
 "name": "accuracy",
 "value": 0.85,
 "type": "Metric"
 },
 {
 "name": "fluency",
 "value": 0.90,
 "type": "Reward"
 }
]
 }
]
```

### Antwortfelder:

- **id:** Muss mit der eingegebenen Proben-ID übereinstimmen
- **aggregate\_reward\_score:** Gesamtpunktzahl (normalerweise 0,0 bis 1,0)
- **metrics\_list:** Array einzelner Metriken mit:
  - **name:** Kennzahl der Metrik (z. B. „Genauigkeit“, „Fließfähigkeit“)
  - **value:** Metrischer Wert (typischerweise 0,0 bis 1,0)
  - **type:** Entweder „Metrik“ (für Berichte) oder „Belohnung“ (wird in Schulungen verwendet)

## IAM-Berechtigungen

### Erforderliche Berechtigungen

Ihre SageMaker KI-Ausführungsrolle muss über Berechtigungen zum Aufrufen Ihrer Lambda-Funktion verfügen. Fügen Sie diese Richtlinie zu Ihrer SageMaker KI-Ausführungsrolle hinzu:

```
{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Effect": "Allow",
 "Action": [
 "lambda:InvokeFunction"
],
 "Resource": "arn:aws:lambda:region:account-id:function:function-name"
 }
]
}
```

### Lambda-Ausführungsrolle

Die Ausführungsrolle Ihrer Lambda-Funktion benötigt grundlegende Lambda-Ausführungsberechtigungen:

```
{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Effect": "Allow",
 "Action": [
 "logs:CreateLogGroup",
 "logs:CreateLogStream",
 "logs:PutLogEvents"
],
 "Resource": "arn:aws:logs:*:*:*"
 }
]
}
```



Zusätzliche Berechtigungen: Wenn Ihre Lambda-Funktion auf andere AWS Dienste zugreift (z. B. Amazon S3 für Referenzdaten, DynamoDB für die Protokollierung), fügen Sie diese Berechtigungen der Lambda-Ausführungsrolle hinzu.

## Ausführung des Evaluierungsjobs

### 1. Bereiten Sie Ihre Daten vor

- Formatieren Sie Ihre Bewertungsdaten gemäß den Anforderungen an das Datenformat
- Laden Sie Ihre JSONL-Datei auf Amazon S3 hoch: `s3://your-bucket/eval-data/eval_data.jsonl`

### 2. Konfigurieren Sie dein Rezept

Aktualisieren Sie das Beispielrezept mit Ihrer Konfiguration:

- Stellen Sie `model_name_or_path` den Standort Ihres Modells ein
- Stellen Sie `lambda_arn` Ihre Belohnungsfunktion ARN ein
- Stellen Sie `output_s3_path` den gewünschten Ausgabeort ein
- Passen Sie die `inference` Parameter nach Bedarf an

Speichern Sie das Rezept unter `rft_eval_recipe.yaml`

### 3. Führen Sie die Evaluierung aus

Führen Sie den Evaluierungsjob mit dem mitgelieferten Notizbuch aus: [Evaluationsnotizbuch für das Modell Nova](#)

### 4. Überwachen Sie den Fortschritt

Überwachen Sie Ihre Bewertungsaufgabe durch:

- SageMaker KI-Konsole: Überprüfen Sie den Auftragsstatus und die Protokolle
- CloudWatch Protokolle: Detaillierte Ausführungsprotokolle anzeigen
- Lambda Logs: Probleme mit der Belohnungsfunktion debuggen

## Evaluierungsergebnisse verstehen

### Ausgabeformat

Der Bewertungsjob gibt die Ergebnisse im JSONL-Format an Ihrem angegebenen Amazon S3 S3-Standort aus. Jede Zeile enthält die Bewertungsergebnisse für eine Probe:

```
{
 "id": "sample-001",
 "aggregate_reward_score": 0.75,
 "metrics_list": [
 {
 "name": "accuracy",
 "value": 0.85,
 "type": "Metric"
 },
 {
 "name": "fluency",
 "value": 0.90,
 "type": "Reward"
 }
]
}
```

#### Note

Die Ausgabe des RFT-Evaluierungsjobs ist identisch mit dem Lambda Response-Format. Der Bewertungsservice durchläuft die Antwort Ihrer Lambda-Funktion unverändert und gewährleistet so die Konsistenz zwischen Ihren Belohnungsberechnungen und den Endergebnissen.

## Interpretation der Ergebnisse

### Gesamter Prämienwert:

- Bereich: Normalerweise 0,0 (am schlechtesten) bis 1,0 (am besten), hängt jedoch von Ihrer Implementierung ab
- Zweck: Eine einzelne Zahl, die die Gesamtleistung zusammenfasst
- Verwendungszweck: Modelle vergleichen, Verbesserungen im Vergleich zu Schulungen verfolgen

### Individuelle Metriken:

- Metriktyp: Informationsmetriken für die Analyse

- Art der Belohnung: Metriken, die während des RFT-Trainings verwendet wurden
- Interpretation: Höhere Werte bedeuten im Allgemeinen eine bessere Leistung (es sei denn, Sie entwerfen inverse Metriken)

## Leistungsmaßstäbe

Was unter „guter“ Leistung zu verstehen ist, hängt von Ihrem Anwendungsfall ab:

| Punktebereich | Interpretation | Action                                                       |
|---------------|----------------|--------------------------------------------------------------|
| 0,8 - 1,0     | Ausgezeichnet  | Modell bereit für den Einsatz                                |
| 0,6 - 0,8     | Gut            | Geringfügige Verbesserungen können von Vorteil sein          |
| 0,4 - 0,6     | Fair           | Signifikante Verbesserung erforderlich                       |
| 0,0 - 0,4     | Schlecht       | Überprüfen Sie die Trainingsdaten und die Belohnungsfunktion |

### Important

Dies sind allgemeine Richtlinien. Definieren Sie Ihre eigenen Schwellenwerte auf der Grundlage der Geschäftsanforderungen, der Leistung des Basismodells, der domänenspezifischen Einschränkungen und der Kosten-Nutzen-Analyse von Weiterbildungsmaßnahmen.

## Überwachung von Jobs mit MLflow HyperPod

Sie können MLflow verwenden, um Ihre Trainingsjobs auf zu verfolgen und zu überwachen. SageMaker HyperPod Folgen Sie diesen Schritten, um MLflow einzurichten und mit Ihren Trainingsrezepten zu verbinden.

### Erstellen Sie die MLflow App

## Beispielbefehl AWS CLI

```
aws sagemaker-mlflow create-mlflow-app \
 --name <app-name> \
 --artifact-store-uri <s3-bucket-name> \
 --role-arn <role-arn> \
 --region <region-name>
```

## Beispielausgabe

```
{
 "Arn": "arn:aws:sagemaker:us-east-1:111122223333:mlflow-app/app-LGZE0Z2UY4NZ"
}
```

## Generieren Sie eine vorsignierte URL

### Beispiel für AWS CLI einen Befehl

```
aws sagemaker-mlflow create-presigned-mlflow-app-url \
 --arn <app-arn> \
 --region <region-name> \
 --output text
```

## Beispielausgabe


```
https://app-LGZE0Z2UY4NZ.mlflow.sagemaker.us-east-1.app.aws/auth?
authToken=eyJhbGciOiJIUzI1NiJ9.eyJhdXRoVG9rZW5JZCI6IkxETVBPUyIsImZhc0NyZWRLbnRpYWxzIjoiQWdWNGhD
```

## Öffnen Sie die vorsignierte URL und sehen Sie sich die App an

### Klick

```
https://app-LGZE0Z2UY4NZ.mlflow.sagemaker.us-east-1.app.aws/auth?
authToken=eyJhbGciOiJIUzI1NiJ9.eyJhdXRoVG9rZW5JZCI6IkxETVBPUyIsImZhc0NyZWRLbnRpYWxzIjoiQWdWNGhD
```

## Anzeigen




Gehen Sie zum Rezept unter dem Ausführungsblock Ihres SageMaker HyperPod Rezepts

### Rezept

```
run
 mlflow_tracking_uri: arn:aws:sagemaker:us-east-1:111122223333:mlflow-app/app-
 LGZE0Z2UY4NZ
```

### Anzeigen



## Iteratives Training

### -Übersicht

Iteratives Training ist der Prozess der wiederholten Feinabstimmung eines Modells durch mehrere Trainingszyklen mit unterschiedlichen Trainingsmethoden — Training, Bewertung, Analyse von Fehlern, Anpassung von data/objectives Hyperparametern — wobei jede Runde am vorherigen Checkpoint beginnt. Dieser Ansatz ermöglicht es Ihnen, systematisch auf Fehlerquellen im Modell einzugehen, kuratierte Beispiele für spezifische Schwächen einzubeziehen und sich im Laufe der Zeit an sich ändernde Anforderungen anzupassen.

Vorteile gegenüber einer Schulung in nur einem Durchgang:

- Gezielte Verbesserung: Behebung spezifischer Fehlermuster, die im Rahmen von Evaluierungen entdeckt wurden
- Adaptive Verfeinerung: Reagieren Sie auf Veränderungen im Vertrieb oder sich ändernde Produkthanforderungen
- Risikominderung: Überprüfen Sie Verbesserungen schrittweise, anstatt sich auf eine einzige lange Schulung festzulegen
- Dateneffizienz: Konzentrieren Sie die Datenerhebung auf Bereiche, in denen das Modell unterdurchschnittlich abschneidet
- Lehrplanausbildung: Mehrere Schulungsrunden mit immer hochwertigeren Daten

## Funktionsweise

### Standort und Zugang zum Checkpoint

Nach Abschluss jedes Trainingsjobs wird eine Manifestdatei an dem durch den `output_path` Parameter in Ihrer Trainingskonfiguration angegebenen Ausgabespeicherort generiert.

Um auf Ihren Checkpoint zuzugreifen

- Navigieren Sie zu Ihrem `output_path` in S3 angegebenen
- Laden Sie die `output.tar.gz` Datei herunter und extrahieren Sie sie
- Öffnen Sie die `manifest.json` Datei im Inneren
- Suchen Sie den `checkpoint_s3_bucket` Parameter, der die S3-URI Ihres trainierten Modells enthält

Beispiel für eine `manifest.json`-Struktur

```
{
 "checkpoint_s3_bucket": "s3://customer-escrow-<account-number>-smtj-<unique-
 identifier>/<job-name>/stepID",
 ...
}
```

## Grundlegendes zu Treuhandbuckets

Da es sich bei Amazon Nova um firmeneigene Prüfpunkte handelt, werden trainierte Modellprüfpunkte in Treuhand-S3-Buckets innerhalb AWS verwalteter Konten gespeichert, anstatt auf Ihr Konto kopiert zu werden. Diese Treuhandkonten:

- Bewahren Sie die Gewichte Ihrer maßgeschneiderten Modelle sicher auf
- Kann von anderen AWS Diensten referenziert werden (Inferenz-, Evaluierungs- und nachfolgende Schulungsaufträge)
- Sind nur für Ihr AWS Konto über IAM-Berechtigungen zugänglich
- Für Ihr Konto fallen die üblichen S3-Speichergebühren an (siehe Überlegungen zu den Kosten)

Sie können den Escrow-Bucket-Pfad als Pfad für Ihren nächsten `model_name_or_path` Trainingslauf verwenden, um das iterative Training fortzusetzen.

## Checkpoints für iteratives Training verwenden

Konfigurieren Sie Ihren nächsten Trainingsjob so, dass er den vorherigen Checkpoint als Basismodell verwendet:

```
run:
 name: "my-iterative-training-job"
 model_type: amazon.nova-2-lite-v1:0:256k
 model_name_or_path: "s3://customer-escrow-<account-number>-smtj-<unique-identifier>/<previous-job-name>"
 data_s3_path: s3://<bucket>/<data-file>.jsonl
 replicas: 4
```

## Wann sollte iteratives Training verwendet werden

### Ideale Anwendungsfälle

Verwenden Sie iteratives Training, wenn Sie:

- Feedbackschleifen — Fähigkeit, reale Fehlerfälle zu sammeln und diese systematisch zu behandeln
- Dynamische Umgebungen — sich weiterentwickelnde Dokumentationen, APIs oder Supportthemen, die regelmäßige Modellaktualisierungen erfordern



- Solide Evaluierung — Starke Benchmarks und Bewertungsrahmen (siehe Beispiele unten), um Verbesserungen zuverlässig messen zu können
- ML-Operationsfähigkeit — Ressourcen zur Verwaltung mehrerer Trainingszyklen und zur Versionskontrolle

### Beispiele für robuste Bewertungsrahmen

- Automatisierte Benchmark-Suiten mit pass/fail Schwellenwerten
- Bewertungsprotokolle durch Menschen mit Zuverlässigkeitsmetriken verschiedener Prüfer
- Red-team Testszenarien, die Randfälle und gegnerische Eingaben abdecken
- A/B Testinfrastruktur zur Messung der Auswirkungen auf die Produktion

## Allgemeine Muster

SFT → RFT-Pipeline: Ein häufig verwendetes iteratives Muster beinhaltet:

- Zuerst SFT — Bringen Sie dem Modell anhand von Demonstrationsbeispielen bei, wie Probleme gelöst werden können
- RFT zweitens — Optimieren Sie die Leistung im breiteren Problembereich mithilfe von Belohnungssignalen

Diese Reihenfolge ist wichtig, wenn Modelle anfänglich schlecht abschneiden. RFT auf Modellen mit einer Genauigkeit von nahezu Null verbessert die Leistung nicht, wenn nicht zuerst grundlegende Problemlösungsfunktionen durch SFT eingerichtet wurden.

## Wann sollte iteratives Training nicht verwendet werden

Vermeiden Sie iteratives Training für:

- Stabile, klar definierte Aufgaben — Stationäre Daten mit konsistenten Anforderungen erreichen bereits nahezu maximale Leistung
- Einfache Klassifizierungsprobleme — Eingeschränkte Aufgaben, bei denen eine Schulung in einem einzigen Durchgang ausreicht
- Ressourcenengpässe — Es fehlen spezielle ML-Betriebsfunktionen zur Verwaltung mehrerer Trainingszyklen

- Marginale Gewinne — Wenn der Overhead minimale Leistungsverbesserungen nicht rechtfertigt

## Beispiel-Workflow: SFT → RFT

Dieses Beispiel zeigt ein gängiges iteratives Trainingsmuster für Argumentationsmodelle.

### Schritt 1: Anfängliches SFT-Training

Konfigurieren und starten Sie Ihren SFT-Trainingsjob mit Ihrem Datensatz:

```
run:
 name: "initial-sft-training"
 model_type: amazon.nova-2-lite-v1:0:256k
 model_name_or_path: "nova-lite-2/prod"
 data_s3_path: s3://<bucket>/sft-training-data.jsonl
 validation_data_s3_path: s3://<bucket>/sft-validation-data.jsonl
```

Begründung: SFT bietet zusätzliche Demonstrationen, in denen die Modellausgaben in das von Ihnen gewünschte Format und Sprache gebracht werden, wodurch grundlegende Funktionen vermittelt werden.

Nach Abschluss der Schulung

- Notieren Sie sich die in Ihrem Trainingsjob `output_path` konfigurierten
- Laden Sie es `output.tar.gz` von diesem Ort herunter
- Extrahieren und lokalisieren `manifest.json`
- Kopieren Sie den `checkpoint_s3_bucket` Wert

### Schritt 2: RFT-Training am SFT-Checkpoint

Erstellen Sie mithilfe des SFT-Checkpoints einen neuen RFT-Trainingsjob:

```
run:
 name: "rft-on-sft-checkpoint"
 model_type: amazon.nova-2-lite-v1:0:256k
 model_name_or_path: "s3://customer-escrow-<account-number>-smtj-<unique-identifier>/<initial-sft-training>"
 data_s3_path: s3://<bucket>/rft-training-data.jsonl
```

```
reward_lambda_arn: <your-reward-function-arn>
```

Begründung: Das RFT-Training baut auf der SFT-Grundlage auf und ermöglicht es dem Modell, komplexere Argumentationsmuster zu entwickeln, die anhand Ihrer Belohnungsfunktion optimiert sind.

### Schritt 3: Evaluieren und iterieren

Führen Sie die Bewertung am RFT-Checkpoint durch, um die Leistung zu bewerten:

```
run:
 name: "evaluate-rft-checkpoint"
 model_type: amazon.nova-2-lite-v1:0:256k
 model_name_or_path: "s3://customer-escrow-<account-number>-smtj-<unique-identifier>/<rft-on-sft-checkpoint>"
 data_s3_path: s3://<bucket>/evaluation-data.jsonl
```

Wenn die Zielkennzahlen nicht erfüllt sind, fahren Sie mit der Iteration mit angepassten Daten oder Hyperparametern fort.

#### Important

Die Trainingstechnik (LoRa vs. Full Rank) muss in allen Iterationen konsistent bleiben:

- Wenn Sie SFT mit LoRa verwenden, müssen Sie RFT mit LoRa verwenden
- Wenn Sie SFT mit vollem Rang verwenden, müssen Sie RFT mit vollständigem Rang verwenden
- Sie können nicht während der Pipeline zwischen LoRa und Full Rank wechseln

#### Important

Wenn ein KMS-Schlüssel für die Verschlüsselung im Amazon-owned S3-Ausgabe-Bucket verwendet wird, muss derselbe KMS-Schlüssel für alle future Iterationen verwendet werden.

## Überwachung des Fortschritts zwischen den Iterationen

Sie können Metriken über MLflow verfolgen, indem Sie [MLflow für Ihre Jobs einrichten](#).

## Erstellen Sie eine MLFlow-App

Verwenden der Studio-Benutzeroberfläche: Wenn Sie einen Trainingsjob über die Studio-Benutzeroberfläche erstellen, wird automatisch eine standardmäßige MLflow-Anwendung erstellt und standardmäßig unter Erweiterte Optionen ausgewählt.

Verwenden von CLI: Wenn Sie die CLI verwenden, müssen Sie eine MLFlow-App erstellen und sie als Eingabe an die API-Anfrage für den Trainingsjob übergeben.

```
mlflow_app_name="<enter your MLflow app name>"
role_arn="<enter your role ARN>"
bucket_name="<enter your bucket name>"
region="<enter your region>"

mlflow_app_arn=$(aws sagemaker create-mlflow-app \
 --name $mlflow_app_name \
 --artifact-store-uri "s3://$bucket_name" \
 --role-arn $role_arn \
 --region $region)
```

## Greifen Sie auf die MLFlow-App zu

Verwenden von CLI: Erstellen Sie eine vorsignierte URL für den Zugriff auf die Benutzeroberfläche der MLflow-App:

```
aws sagemaker create-presigned-mlflow-app-url \
 --arn $mlflow_app_arn \
 --region $region \
 --output text
```

Verwenden der Studio-Benutzeroberfläche: Die Studio-Benutzeroberfläche zeigt wichtige Kennzahlen an, die in MLflow gespeichert sind, und bietet einen Link zur Benutzeroberfläche der MLflow-App.

## Wichtige Kennzahlen, die es zu verfolgen gilt

Überwachen Sie diese Kennzahlen in allen Iterationen, um die Verbesserung zu bewerten und den Arbeitsfortschritt zu verfolgen:

Für SFT

- Verlustkurven beim Training

- Anzahl der verbrauchten Proben und Dauer der Probenverarbeitung
- Leistungsgenauigkeit bei ausgestreckten Testgeräten
- Formatkonformität (z. B. gültige JSON-Ausgaberate)
- Unklarheit in Bezug auf domänenspezifische Bewertungsdaten

## Für RFT

- Durchschnittliche Belohnungspunktzahl im Vergleich zum Training
- Verteilung der Prämien (Prozentsatz der Antworten mit hoher Prämie)
- Trends bei der Validierung von Prämien (achten Sie auf Überbelegungen)
- Task-specific Erfolgsquoten (z. B. Erfolgsquote bei der Codeausführung, Genauigkeit mathematischer Probleme)

## General

- Vergleichen Sie Leistungsdeltas zwischen Iterationen
- Bewertungsergebnisse am Menschen anhand repräsentativer Stichproben
- Produktionskennzahlen (bei iterativer Bereitstellung)

## Feststellen, wann gestoppt werden soll

Beenden Sie die Iteration, wenn:

- Leistungsplateaus — Zusätzliche Schulungen verbessern die Zielkennzahlen nicht mehr nennenswert
- Technikwechsel hilft — Wenn eine Technik ein Plateau erreicht, versuchen Sie es mit einem Wechsel (z. B. SFT → RFT → SFT), um die Leistungsobergrenzen zu durchbrechen
- Zielkennzahlen erreicht — Ihre Erfolgskriterien sind erfüllt
- Regression erkannt — Neue Iterationen verschlechtern die Leistung (siehe Rollback-Verfahren unten)

Ausführliche Bewertungsverfahren finden Sie im Abschnitt [Bewertung](#).

## Best Practices

### Fangen Sie klein an und skalieren Sie schrittweise

Beginnen Sie mit minimalen Datensätzen und einzelnen Trainingsepochen, um Ihren Ansatz zu validieren, bevor Sie ihn skalieren. Das schafft Vertrauen und hilft, Probleme frühzeitig zu erkennen.

### Legen Sie klare Erfolgskennzahlen fest

Definieren Sie quantitative und qualitative Indikatoren, bevor Sie beginnen:

Beispiele für Erfolgskennzahlen nach Anwendungsfall

- Beantwortung von Fragen — Genaue Treffergenauigkeit, F1-Ergebnis, menschliche Präferenzwerte
- Codegenerierung — Erfolgsquote bei Komponententests, Erfolg bei der Kompilierung, Ausführungszeit
- Aufgaben zum Argumentieren — Schrittgenauigkeit, Richtigkeit der endgültigen Antwort, Prämienpunktzahl
- Generierung von Inhalten — Kohärenzwerte, sachliche Genauigkeit, Einhaltung des Stils

### Implementieren Sie eine automatisierte Bewertung

Richten Sie automatisierte Evaluierungspipelines ein, um die Leistung nach jeder Runde zu verfolgen und so eine schnelle Iteration und einen objektiven Vergleich zu ermöglichen.

### Sorgen Sie für eine strenge Versionskontrolle

Dokument für jede Iteration:

- Versionen und Änderungen von Datensätzen
- Modellieren Sie die Standorte von Checkpoints
- Änderungen der Hyperparameter
- Leistungskennzahlen und Deltas
- Qualitative Beobachtungen

Dadurch wird institutionelles Wissen aufgebaut und das Debuggen ermöglicht.

## Konzentrieren Sie sich auf Datenqualität statt Quantität

Analysieren Sie Fehlerfälle aus früheren Runden und fügen Sie gezielte, qualitativ hochwertige Beispiele hinzu, anstatt einfach die Datenmenge zu vergrößern.

## Planen Sie das Budget für die Iteration

Planen Sie für einen typischen Zeitraum von 3 bis 5 Iterationen ein:

- 1—2 Iterationen — Oft ausreichend für einfache Verbesserungen oder den letzten Feinschliff
- 3—5 Iterationen — Geeignet für komplexe Aufgaben, die mehrere Verfeinerungszyklen erfordern
- Mehr als 5 Iterationen — Kann auf sinkende Erträge oder die Notwendigkeit unterschiedlicher Ansätze hinweisen

Passen Sie die Anpassung auf der Grundlage des rechnerischen Budgets und der Leistungsverbesserungsraten an.

## Implementieren Sie Rollback-Funktionen

Wenn eine Iteration Regressionen einführt:

- Identifizieren Sie die Regression — Vergleichen Sie die Bewertungskennzahlen der Checkpoints
- Zurück zum vorherigen Checkpoint — Verwenden Sie den S3-Pfad des früheren Checkpoints als `model_name_or_path`
- Trainingsansatz anpassen — Ändern Sie Daten, Hyperparameter oder Technik, bevor Sie es erneut versuchen
- Dokumentieren Sie den Fehler — Notieren Sie, was die Regression verursacht hat, um Wiederholungen zu vermeiden

## Beispiel für einen Rollback

```
run:
 name: "rollback-to-iteration-2"
 model_type: amazon.nova-2-lite-v1:0:256k
 # Use iteration 2 checkpoint instead of failed iteration 3
 model_name_or_path: "s3://customer-escrow-<account-number>-smtj-<unique-identifier>/
<iteration-2-job-name>"
```

# Kostenüberlegungen

## Checkpoint-Speicher

- Standort — Für Checkpoints, die in Treuhandbüchern gespeichert sind, fallen die üblichen S3-Speichergebühren an, die Ihrem Konto in Rechnung gestellt werden AWS
- Aufbewahrung — Checkpoints werden auf unbestimmte Zeit aufbewahrt, sofern sie nicht ausdrücklich gelöscht werden
- Verwaltung — Implementieren Sie Lebenszyklusrichtlinien, um alte Checkpoints, die Sie nicht mehr benötigen, zu archivieren oder zu löschen

## Tipps zur Kostenoptimierung

- Löschen Sie Zwischen-Checkpoints, nachdem Sie neuere Iterationen validiert haben
- Archivieren Sie Checkpoints auf S3 Glacier für eine langfristige Aufbewahrung zu geringeren Kosten
- Legen Sie Aufbewahrungsrichtlinien auf der Grundlage Ihrer Compliance- und Testanforderungen fest

## Einschränkungen

### Modellieren Sie die Konsistenz der Familie

Beim iterativen Training müssen Sie in allen Iterationen denselben Modelltyp verwenden.

### Anfängliches Training

```
run:
 model_type: amazon.nova-2-lite-v1:0:256k
 model_name_or_path: "nova-lite-2/prod"
```

### Nachfolgende Iterationen müssen denselben Model\_Type verwenden

```
run:
 model_type: amazon.nova-2-lite-v1:0:256k # Must match original
 model_name_or_path: "s3://customer-escrow-<account-number>-smtj-<unique-identifier>/<job-name>"
```



## Konsistenz der Trainingstechnik

Die Trainingstechnik muss in allen Iterationen konsistent bleiben:

- LoRA-trained Modelle können nur iterativ mit LoRa trainiert werden
- Full-Rank-trained Modelle können nur iterativ trainiert werden mit Full-Rank

Wie funktionieren LoRa-Adapter im iterativen Training

- Jede LoRa-Trainingsiteration produziert neue Adaptergewichte
- Adapter aus jeder Phase werden auf der Grundlage der von Ihnen angegebenen Zusammenführungsgewichte zusammengeführt. Einzelheiten dazu, wie Adapter zusammengeführt werden, finden Sie unter [LoRa-Feinabstimmung](#) in der Dokumentation zur Modellzusammenführung.
- Das Basismodell bleibt eingefroren; nur Adapter werden aktualisiert

## Kompatibilitätsmatrix für die Technik

| Erstausbildung    | Kann mit iterieren                 |
|-------------------|------------------------------------|
| SFT ( ) Full-Rank | SFT (Full-Rank), RFT ( ) Full-Rank |
| SFT (LoRa)        | SFT (LoRa), RFT (LoRa)             |
| RFT ( ) Full-Rank | RFT ( ) Full-Rank                  |
| RFT (LoRa)        | RFT (LoRa)                         |

Überprüfung der Kompatibilität vor Beginn eines Jobs

- Überprüfe dein vorheriges Trainingsrezept, um den Modelltyp und die Trainingstechnik zu identifizieren (LoRa vs.) Full-Rank
- Vergewissere dich, dass dein neues Rezept sowohl dem Modelltyp als auch der Technik entspricht
- Überprüfen Sie die Datei manifest.json, um sicherzustellen, dass der Checkpoint-Pfad korrekt ist

## Fehlerbehebung

### Fehler: „Inkompatible Modelltrainingstechniken erkannt“

Ursache: Die Trainingstechnik (LoRa vs. Full-Rank) stimmt nicht mit der Technik des Checkpoints überein.

Lösung: Stellen Sie sicher, dass Ihr Rezept dieselbe Trainingstechnik wie das Originalmodell verwendet:

- Wenn der Checkpoint mit LoRa trainiert wurde, verwenden Sie LoRa in Ihrem neuen Rezept
- Wenn der Checkpoint mit trainiert wurde Full-Rank, verwende Full-Rank es in deinem neuen Rezept

### Fehler: „Das Basismodell für den aus model\_name\_or\_path extrahierten Job stimmt nicht mit model\_type überein“

Ursache: Der in angegebene Modelltyp entspricht model\_type nicht dem tatsächlichen Modell im Checkpoint.

Lösung: Stellen Sie sicher, dass:

- Der model\_type in Ihrem Rezept angegebene Typ entspricht dem ursprünglichen Modelltyp
- Der Checkpoint S3-Pfad model\_name\_or\_path ist korrekt
- Sie verwenden den Pfad aus der richtigen manifest.json-Datei

### Beispiel für eine korrekte Konfiguration

```
run:
 model_type: amazon.nova-2-lite-v1:0:256k # Must match checkpoint's model
 model_name_or_path: "s3://customer-escrow-<account-number>-smtj-<unique-identifier>/<job-name>"
```

### Fehler: „Modellkonfiguration nicht gefunden“

Ursache: Der S3-Pfad in model\_name\_or\_path ist ungültig oder es kann nicht darauf zugegriffen werden.

## Auflösung

- Stellen Sie sicher, dass der S3-Pfad korrekt aus der Datei manifest.json kopiert wurde
- Stellen Sie sicher, dass Ihre IAM-Rolle über Berechtigungen für den Zugriff auf den Treuhandbereich verfügt
- Bestätigen Sie, dass der vorherige Schulungsjob erfolgreich abgeschlossen wurde
- Überprüfen Sie den Pfad auf Tippfehler

## Leistungsrückgang nach der Iteration

Symptome: Die Bewertungskennzahlen nehmen nach einer neuen Trainingsiteration ab.

### Auflösung

- Rollback — Verwenden Sie den vorherigen Checkpoint als Basismodell
- Analysieren — Überprüfen Sie die Trainingsprotokolle und die Datenqualität für die fehlgeschlagene Iteration
- Anpassen — Ändern Sie Hyperparameter (reduzieren Sie die Lernrate), verbessern Sie die Datenqualität oder verkürzen Sie Trainingsepochen
- Wiederholen — Startet eine neue Iteration mit Anpassungen

## Modell Merge

### Important

In diesem Dokument werden wir „Basismodell“ als eines der beiden Modelle bezeichnen. Es kann das ursprüngliche Basismodell (z. B. Nova Lite 2.0) sein, wenn kein [iteratives Training](#) durchgeführt wurde, oder das Ergebnis des vorherigen [iterativen Trainingslaufs](#).

Nach Abschluss der Feinabstimmung durchläuft Ihr benutzerdefiniertes Modell einen optionalen, vom Benutzer konfigurierbaren Schritt zur Modellzusammenführung, bei dem das neu erlernte Wissen mit den Funktionen des „Basismodells“ kombiniert wird. Dieser Prozess stellt sicher, dass Ihr endgültiges Modell die ursprüngliche Intelligenz des „Basismodells“ beibehält und gleichzeitig das spezielle Verhalten berücksichtigt, das Sie während des letzten Feinabstimmungstrainings gelernt

haben. Durch die Modellzusammenführung wird ein Phänomen, das als katastrophales Vergessen bezeichnet wird, abgemildert, bei dem ein Modell zuvor erlerntes Wissen verliert, nachdem es anhand neuer Daten verfeinert wurde.

## Anwendbarkeit der Modellzusammenführung nach Schulungstyp

Das Zusammenführen von Modellen ist nur für SFT-Schulungen konfigurierbar. In der folgenden Tabelle wird das Verhalten beim Zusammenführen von Modellen für jeden Trainingstyp zusammengefasst:

| Art des Trainings                               | Verhalten beim Zusammenführen von Modellen                                                                                                                                                                     |
|-------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <a href="#">Beaufsichtigt Fine-Tuning (SFT)</a> | User-configurable Die Modellzusammenführung wird angewendet. Sie können das Gewicht der Zusammenführung zwischen dem fein abgestimmten Modell und dem Basismodell steuern, wie in diesem Dokument beschrieben. |
| <a href="#">Verstärkung Fine-Tuning (RFT)</a>   | Keine Modellzusammenführung. Der Checkpoint für das trainierte Modell wird direkt als das endgültige Modell ausgegeben. An einem Zusammenführungsschritt ist kein Basismodell beteiligt.                       |
| <a href="#">Fortsetzung Pre-Training (CPT)</a>  | Keine Modellzusammenführung. Der Checkpoint für das trainierte Modell wird direkt als das endgültige Modell ausgegeben. An einem Zusammenführungsschritt ist kein Basismodell beteiligt.                       |

## Wann sollte das Zusammenführen von Modellen verwendet werden

Sie sollten die Modellzusammenführung in folgenden Fällen aktivieren:

- Die allgemeinen Funktionen verschlechtern sich nach der Feinabstimmung. Wenn Ihr fein abgestimmtes Modell bei Aufgaben, die nicht zu Ihren Trainingsdaten gehören, an Leistung verliert (z. B. Mathematik, Argumentation oder Programmieren), wird beim Zusammenführen das Wissen aus dem Basismodell zusammengeführt, um diese Fähigkeiten wiederherzustellen.
- Iterative/continual Training. Bei der Feinabstimmung zusätzlich zu einem zuvor angepassten Checkpoint ist die Zusammenführung unerlässlich, um die in früheren Runden erlernten Fähigkeiten beizubehalten. Andernfalls kann jede neue Runde das, was in der vorherigen Runde gelehrt wurde, überschreiben.

In folgenden Fällen ist eine Modellzusammenführung möglicherweise nicht erforderlich:

- Sie möchten nur die Leistung der Zielaufgabe maximieren, und die generelle Beibehaltung von Fähigkeiten ist kein Problem.
- Bergsteigen. Sie möchten mit demselben Datensatz weiter iterieren, um die Evaluierungsleistung weiter zu optimieren.
- Sie verwenden eine auf Argumenten basierende Feinabstimmung. Studien haben gezeigt, dass eine auf Argumenten basierende SFT katastrophales Vergessen erheblich abmildert.

## Wie konfiguriert man Gewichte für die Zusammenführung von Modellen

Der Standardwert `model_importance_score.fine_tuned_model` ist 1,0, was bedeutet, dass der Trainings-Output-Checkpoint ausschließlich die fein abgestimmten Gewichte verwendet, ohne dass es zu einer Mischung aus dem „Basismodell“ kommt. Die Standardeinstellung funktioniert gut, wenn Ihre Trainingsdaten umfassend sind und Ihrer Zielaufgabe sehr nahe kommen.

Sie können steuern, wie das endgültige Modell ein Gleichgewicht zwischen Spezialisierung und Allgemeinwissen herstellt, indem Sie dies `model_importance_score` in Ihren [Hyperparametern](#) festlegen. Beispiel:

```
training_config:
...
 model_importance_score:
 fine_tuned_model: 0.75 # set value between 0.0 to 1.0 inclusive
```

`model_importance_score.fine_tuned_model` Bei Werten, die näher an 1,0 liegen, orientiert sich das Modell eher an Ihren fein abgestimmten Daten, während bei Werten, die näher an 0,0 liegen, die allgemeinen Funktionen des Basismodells in größerem Umfang erhalten bleiben. Im obigen Beispiel wird das endgültige trainierte Modell erstellt, indem das zu 75% fein abgestimmte Modell des spezifischen Datensatzes mit 25% des „Basismodells“ zusammengeführt wird.

Wenn Sie feststellen, dass Ihr fein abgestimmtes Modell an allgemeinen Fähigkeiten verliert (z. B. verminderte Leistung bei Aufgaben außerhalb Ihrer Trainingsdaten), reduzieren Sie es, `model_importance_score.fine_tuned_model` um mehr Wissen aus dem „Basismodell“ einfließen zu lassen.

**Note**

Wir können zwar die Gewichte der Modellzusammenführung konfigurieren, aber der Benutzer kann nicht wählen, mit welchen Modellen er zusammengeführt werden soll. Mit anderen Worten, es wird immer zwischen dem „Basismodell“ und dem fein abgestimmten Modell des aktuellen Trainingslaufs liegen. Das „Basismodell“ kann das ursprüngliche Basismodell (z. B. Nova Lite 2.0) oder das Ergebnis des vorherigen [iterativen Trainingslaufs](#) sein.

## Modell wählen, Gewichte zusammenführen

Der `model_importance_score.fine_tuned_model` Parameter steuert das Gleichgewicht zwischen Ihrem fein abgestimmten Modell und dem Basismodell. Beginnen Sie mit diesen Richtlinien:

| Szenario                                                               | Empfohlenes Startgewicht              | Begründung                                                                                                                                                                                                    |
|------------------------------------------------------------------------|---------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Single-round SFT mit umfassenden Trainingsdaten                        | 1.0 (Standard, keine Zusammenführung) | Ihre Trainingsdaten decken die Zielaufgabe gut ab. Eine Zusammenführung würde erlerntes Verhalten ohne Nutzen verwässern.                                                                                     |
| Single-round SFT, wenn sich die allgemeinen Fähigkeiten verschlechtern | 0,7—0,9                               | Kombiniert ausreichend Basismodellwissen, um allgemeine Fähigkeiten (Mathematik, Argumentation, Programmieren) wiederherzustellen und gleichzeitig den Großteil der fein abgestimmten Leistung beizubehalten. |
| Iterative/continual SFT (baut auf einem früheren Checkpoint auf)       | 0,3—0,7                               | Bei niedrigeren Gewichten ist mehr Wissen aus früheren Trainingsrunden enthalten. Ohne Zusammenführung können spätere Runden die in früheren Runden erlernten Fähigkeiten überschreiben.                      |
| Explorativ//unsicher                                                   | 0.7                                   | Ein vernünftiger Mittelweg; Anpassung auf der Grundlage der Bewertungsergebnisse.                                                                                                                             |

Allgemeines Prinzip: Höhere Gewichte (näher an 1,0) maximieren die Leistung der Zielaufgabe, bergen jedoch die Gefahr, dass allgemeine Fähigkeiten verloren gehen. Niedrigere Gewichtungen (näher an 0,0) behalten die allgemeinen Fähigkeiten des Basismodells bei, verringern jedoch die Spezialisierung. Es gibt keinen allgemein optimalen Wert — die richtige Gewichtung hängt von der Größe Ihres Datensatzes, der Domänenüberschneidung mit dem Basismodell und den Funktionen ab, die Sie beibehalten müssen.

 Tip

Wenn Ihre Trainingsdaten Argumentationsspuren (Gedankenkette) enthalten, können Sie in der Regel eine höhere Gewichtung bei der Zusammenführung verwenden (oder die Zusammenführung bei 1,0 komplett überspringen), da mit Argumentation erweiterte Daten als Regulator dienen, der allgemeine Fähigkeiten beibehält.

## Dein Gewicht beim Zusammenführen auswerten

Evaluieren Sie nach Abschluss des Trainings das zusammengeführte Modell, um sicherzustellen, dass das zusammengeführte Gewicht angemessen ist. Du brauchst nicht mehrere Trainingsläufe — ein einziger Testdurchgang kann dir sagen, ob du dich anpassen musst.

- Leistung der Zielaufgabe — Führen Sie Ihre domänenspezifische Bewertung (Genauigkeit, F1, Extraktionswert usw.) anhand eines Testsatzes aus, der Ihnen zur Verfügung steht. Vergleichen Sie mit dem Basismodell (vor jeder Feinabstimmung), um sicherzustellen, dass die Feinabstimmung die Leistung verbessert hat. Wenn der Gewinn gegenüber dem Basismodell geringer als erwartet ausfällt, ist Ihr Zusammenführungsgewicht möglicherweise zu gering — die Gewichte des Basismodells verwässern das, was während des Trainings gelernt wurde.
- Stichprobenprüfung allgemeiner Fähigkeiten — Fordere das zusammengeführte Modell mit einigen Aufgaben auf, die nicht zu deiner Trainingsdomäne gehören (z. B. eine mathematische Wortaufgabe, eine Zusammenfassungsanfrage oder eine Programmierfrage). Vergleichen Sie die Antworten qualitativ mit dem Basismodell. Wenn die Antworten des zusammengeführten Modells deutlich schlechter sind als die des Basismodells — inkohärent, Weigerung zu antworten oder Kauderwelsch über Aufgaben, die das Basismodell gut bewältigt —, ist Ihr Zusammenführungsgewicht zu hoch und das Modell hat an allgemeinen Fähigkeiten verloren.

## So funktioniert das Zusammenführen: Feinabstimmung Full-rank

Full-rank Beim Training wird ein vollständiger Satz von Modellgewichten erstellt. Beim Zusammenführen wird jeder Parameter als gewichtete Mischung berechnet:

```
Weighted interpolation
Merged Model = (1 - model_importance_score.fine_tuned_model) * Base Model +
model_importance_score.fine_tuned_model * Fine-Tuned Model
```

Beispielsweise besteht das zusammengeführte Modell zu 70% aus Basismodellwissen und zu 30% aus detailliertem Wissen. `model_importance_score.fine_tuned_model = 0.3`

## So funktioniert die Zusammenführung: LoRa-Feinabstimmung

LoRa (Low-Rank Adaptation) lernt ein kompaktes Paar von Matrizen mit niedrigem Rang (A und B), die die Anpassung als Low-Rank-Update darstellen. Während der Modellzusammenführung wird jede A- und B-LoRa-Matrix wie folgt skaliert. `model_importance_score.fine_tuned_model` In diesen Formeln `alpha` steht der LoRa-Skalierungsfaktor (`peft.lora_tuning.alphain` Ihrem Trainingsrezept) und der `rank` LoRa-Rang. Die verfügbaren `alpha` Werte finden Sie im [LoRa SFT-Trainingsrezept](#).

Beachten Sie, dass die A- und B-Matrizen derzeit nur Erkenntnisse aus dem letzten Feinabstimmungslauf enthalten. Es liegen keine Kenntnisse über frühere Trainingsläufe vor. Das Wissen aus früheren Trainingsläufen stammt aus der Verschmelzung des Modells mit dem „Basismodell“ oder der unten beschriebenen Zusammenführung von LoRa-Adaptern in der vorherigen Phase.

```
Scaled_A = sqrt(model_importance_score.fine_tuned_model) * sqrt(alpha/rank) * A
Scaled_B = sqrt(model_importance_score.fine_tuned_model) * sqrt(alpha/rank) * B
```

Beim LoRa-Training werden zwei Modellartefakte erzeugt: ein vollständig zusammengeführtes Modell und ein Satz zusammengeführter LoRa-Adapter. Schauen wir uns jeden von ihnen einzeln an.

Vollständig zusammengeführtes Modell

Das LoRa-Update wird skaliert und dem „Basismodell“ hinzugefügt:



$$\text{Merged Model} = \text{Base Model} + (\text{Scaled\_B} @ \text{Scaled\_A})$$

Nun Merged Model hat er sowohl Wissen aus dem aktuellen Trainingslauf als auch etwas Wissen aus der Base Model je nach Anwender konfigurierten.

`model_importance_score.fine_tuned_model`

### Zusammengeführte LoRa-Adapter

Wie die LoRa-Adapter zusammengeführt werden, hängt davon ab, ob Sie ein einstufiges oder iteratives Training durchführen.

- Bei einstufigem LoRa-Training (kein iteratives Training) werden die fein abgestimmten LoRa-Adapter ohne Zusammenführung direkt gespeichert, da es keinen vorherigen Satz von LoRa-Adaptoren gibt, mit denen zusammengeführt werden kann.
- In [iterativen All-LoRa-Workflows](#) werden die Adapter aus jeder Phase zu einem einzigen Satz zusammengeführt:

$$\text{Merged} = \text{Stage1\_Scaled\_B} @ \text{Stage1\_Scaled\_A} + \text{Stage2\_Scaled\_B} @ \text{Stage2\_Scaled\_A}$$

Die Merged LoRa-Adapter enthalten Informationen über frühere Trainingsiterationen sowie die neuesten Erkenntnisse zur Feinabstimmung, basierend auf den benutzerdefinierten Daten.

`model_importance_score.fine_tuned_model`

Bitte achten Sie auch genau auf die [Einschränkungen beim wiederholten Training bei der Kombination von LoRa und Training](#). Full-rank

Diese zusammengeführten Adapter Merged\_B Merged\_A geben die gesamte Trainingshistorie wieder und werden für [On-Demand-Inferenzen](#) verwendet.

## SageMaker Folgerung

Benutzerdefinierte Amazon Nova-Modelle sind jetzt auf SageMaker Inference verfügbar. Wenn Amazon Nova aktiviert ist SageMaker, können Sie damit beginnen, Prognosen oder Schlussfolgerungen aus Ihren trainierten benutzerdefinierten Amazon Nova-Modellen zu ziehen.

SageMaker bietet eine breite Auswahl an Optionen zur ML-Infrastruktur und Modellbereitstellung, um all Ihren Anforderungen an ML-Inferenz gerecht zu werden. Mit SageMaker Inferenz können Sie Ihre Modellbereitstellung skalieren, Modelle in der Produktion effektiver verwalten und den betrieblichen Aufwand reduzieren.

SageMaker bietet Ihnen verschiedene Inferenzoptionen, z. B. Echtzeit-Endpunkte für Inferenzen mit geringer Latenz und asynchrone Endpunkte für Batches von Anfragen. Indem Sie die für Ihren Anwendungsfall geeignete Inferenzoption nutzen, können Sie eine effiziente Modellbereitstellung und Inferenz sicherstellen. [Weitere Informationen zur Inferenz finden Sie unter Bereitstellen von Modellen für SageMaker Inferenz.](#)

 **Important**

Bei Inferenz werden nur benutzerdefinierte Modelle und LoRA-merged Modelle mit vollem Rang unterstützt. SageMaker Verwenden Sie Amazon Bedrock für nicht zusammengeführte LoRa-Modelle und Basismodelle.

## Features

Die folgenden Funktionen sind für Amazon Nova-Modelle auf SageMaker Inferenz verfügbar:

### Funktionen des Modells

- Textgenerierung

### Bereitstellung und Skalierung

- Real-time Endpunkte mit benutzerdefinierter Instanzauswahl
- Auto Scaling — Passen Sie die Kapazität automatisch an die Verkehrsmuster an, um Kosten und GPU-Auslastung zu optimieren. Weitere Informationen finden Sie unter [Automatisches Skalieren von SageMaker Amazon-Modellen](#).
- Streaming-API-Unterstützung für die Token-Generierung in Echtzeit

### Überwachung und Optimierung

- CloudWatch Amazon-Integration für Überwachung und Benachrichtigungen
- Optimierung der Verfügbarkeit und Zone-aware Latenz durch VPC-Konfiguration

## Entwicklungstools

- AWS CLI support — Weitere Informationen finden Sie in der [AWS CLI-Befehlsreferenz für SageMaker](#).
- Notebook-Integration über SDK-Unterstützung

## Unterstützte Modelle und Instanzen

Bei der Erstellung Ihrer SageMaker Inferenzendpunkte können Sie zwei Umgebungsvariablen festlegen, um Ihre Bereitstellung zu konfigurieren: `CONTEXT_LENGTH` und `MAX_CONCURRENCY`

- `CONTEXT_LENGTH`— Maximale Gesamtlänge des Tokens (Eingabe + Ausgabe) pro Anfrage
- `MAX_CONCURRENCY`— Maximale Anzahl gleichzeitiger Anfragen, die der Endpunkt bearbeiten wird

In der folgenden Tabelle sind die unterstützten Amazon Nova-Modelle, Instance-Typen und unterstützten Konfigurationen aufgeführt. Die `MAX_CONCURRENCY`-Werte stellen die maximale unterstützte Parallelität für jede `CONTEXT_LENGTH`-Einstellung dar:

| Modell            | Instance-Typ   | Unterstützte Konfigurationen                                                                                                                                 | FP8-Quantisierung erforderlich |
|-------------------|----------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------|
| Amazon Nova Micro | ml.g5.12xlarge | <code>CONTEXT_LENGTH</code> : 4000,<br><code>MAX_PARALLELITÄT</code> : 12<br><br><code>KONTEXTLÄNGE</code> : 8000,<br><code>MAXIMALE PARALLELITÄT</code> : 6 | Nein                           |
|                   | ml.g5.24xlarge | <code>KONTEXTLÄNGE</code> : 8000,<br><code>MAXIMALE PARALLELITÄT</code> : 8                                                                                  | Nein                           |
|                   | ml.g6e.xlarge  | <code>KONTEXTLÄNGE</code> : 8000,<br><code>MAXIMALE PARALLELITÄT</code> : 2                                                                                  | Nein                           |

| Modell | Instance-Typ   | Unterstützte Konfigurationen                                                                                                                                         | FP8-Quantisierung erforderlich |
|--------|----------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------|
|        | ml.g6e.2xlarge | KONTEXTLÄNGE: 8000,<br>MAXIMALE PARALLELITÄT: 2                                                                                                                      | Nein                           |
|        | ml.g6e.4xlarge | KONTEXTLÄNGE: 8000,<br>MAXIMALE PARALLELITÄT: 4                                                                                                                      | Nein                           |
|        | ml.g6.12xlarge | KONTEXTLÄNGE: 4000,<br>MAXIMALE PARALLELITÄT: 12<br><br>KONTEXTLÄNGE: 8000,<br>MAXIMALE PARALLELITÄT: 6                                                              | Nein                           |
|        | ml.g6.24xlarge | KONTEXTLÄNGE: 8000,<br>MAXIMALE PARALLELITÄT: 8                                                                                                                      | Nein                           |
|        | ml.g6.48xlarge | KONTEXTLÄNGE: 8000,<br>MAXIMALE PARALLELITÄT: 12                                                                                                                     | Nein                           |
|        | ml.p5.48xlarge | KONTEXTLÄNGE: 16000,<br>MAXIMALE PARALLELITÄT: 128<br><br>KONTEXTLÄNGE: 64000,<br>MAXIMALE PARALLELITÄT: 32<br><br>KONTEXTLÄNGE: 128000,<br>MAXIMALE PARALLELITÄT: 8 | Nein                           |

| Modell           | Instance-Typ   | Unterstützte Konfigurationen                                                                               | FP8-Quantisierung erforderlich |
|------------------|----------------|------------------------------------------------------------------------------------------------------------|--------------------------------|
| Amazon Nova Lite | ml.g6.12xlarge | KONTEXTLÄNGE: 8000,<br>MAXIMALE PARALLELITÄT: 2                                                            | Ja — Standardmäßig aktiviert   |
|                  | ml.g6.24xlarge | CONTEXT_LENGTH: 8000,<br>MAX_CONCURRENCY: 4                                                                | Ja — Standardmäßig aktiviert   |
|                  | ml.g6.48xlarge | CONTEXT_LENGTH: 4000,<br>MAX_CONCURRENCY: 16<br><br>KONTEXTLÄNGE: 8000,<br>MAXIMALE PARALLELITÄT: 8        | Nein                           |
|                  | ml.p5.48xlarge | KONTEXTLÄNGE: 16000,<br>MAXIMALE PARALLELITÄT: 128<br><br>KONTEXTLÄNGE: 60000,<br>MAXIMALE PARALLELITÄT: 8 | Nein                           |
| Nova 2 Lite      | ml.g6.48xlarge | KONTEXTLÄNGE: 8000,<br>MAXIMALE PARALLELITÄT: 8                                                            | Ja — Standardmäßig aktiviert   |

| Modell | Instance-Typ   | Unterstützte Konfigurationen                                                                                                                                                                                         | FP8-Quantisierung erforderlich |
|--------|----------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------|
|        | ml.p5.48xlarge | <p>CONTEXT_LENGTH: 16000, MAX_CONCURRENCY: 128</p> <p>KONTEXTLÄNGE: 64000, MAXIMALE PARALLELITÄT: 32</p> <p>KONTEXTLÄNGE: 128000, MAXIMALE PARALLELITÄT: 8</p> <p>KONTEXTLÄNGE: 256000, MAXIMALE PARALLELITÄT: 2</p> | Nein                           |

### Note

In Fällen, in denen die FP8-Quantisierung erforderlich ist, ist sie standardmäßig aktiviert. Die angezeigten MAX\_CONCURRENCY-Werte sind Obergrenzen für jede CONTEXT\_LENGTH-Einstellung. Sie können niedrigere Kontextlängen bei derselben Parallelität verwenden, aber eine Überschreitung dieser Werte führt dazu, dass die Endpunkterstellung fehlschlägt. SageMaker

Zum Beispiel auf Amazon Nova Micro mit einem ml.g5.12xlarge:

- CONTEXT\_LENGTH=2000 MAX\_CONCURRENCY=12, → Gültig
- CONTEXT\_LENGTH=8000, MAX\_CONCURRENCY=12 → Abgelehnt (Parallelitätslimit ist 6 bei einer Kontextlänge von 8000)
- CONTEXT\_LENGTH=8000, MAX\_CONCURRENCY=4 → Gültig
- CONTEXT\_LENGTH=8000, MAX\_CONCURRENCY=6 → Gültig
- CONTEXT\_LENGTH=10000 → Abgelehnt (die maximale Kontextlänge beträgt 8000 auf dieser Instanz)

## Inferenzkomponenten

Sie können Amazon Nova-Modelle mithilfe von SageMaker Inferenzkomponenten bereitstellen, die es Ihnen ermöglichen, mehrere Modelle auf einem einzigen Endpunkt zu hosten und die Ressourcennutzung zu optimieren. Mit Inferenzkomponenten können Sie die Rechenressourcen (CPU, Arbeitsspeicher, GPU) angeben, die für jedes Modell erforderlich sind, wodurch effizientes Hosting mehrerer Modelle auf einer gemeinsam genutzten Infrastruktur ermöglicht wird.

In der folgenden Tabelle sind die Mindestanforderungen an Rechenressourcen für jedes Amazon Nova-Modell aufgeführt, wenn Inferenzkomponenten verwendet werden:

| Modell            | Minimale Anzahl an CPU-Kernen | Minimaler Arbeitsspeicher (MB) | Minimale GPU-Anzahl |
|-------------------|-------------------------------|--------------------------------|---------------------|
| Amazon Nova Micro | 15                            | 25000                          | 4                   |
| Amazon Nova Lite  | 20                            | 35000                          | 4                   |
| Nova 2 Lite       | 20                            | 100000                         | 4                   |

### Note

Die `ComputeResourceRequirements` Werte müssen die in der obigen Tabelle aufgeführten Mindestanforderungen für das Modell, das Sie bereitstellen, erfüllen oder übertreffen. Wenn Sie Werte verwenden, die unter den Mindestanforderungen liegen, schlägt die Erstellung der Inferenzkomponenten fehl.

Sie können mehrere Inferenzkomponenten auf demselben Endpunkt bereitstellen, sofern die Gesamtressourcenanforderungen die Kapazität der Instanz nicht überschreiten.

Die Anzahl der Inferenzkomponenten, die Sie auf einem einzelnen Endpunkt hosten können, hängt von den verfügbaren Ressourcen des Instanztyps und den Mindestanforderungen der einzelnen Modelle ab. Zum Beispiel auf einem `m1.p5.48xlarge` (8 GPUs, 192 vCPUs, ~1 TB Speicher):

- 1 Amazon Nova Micro-Inferenzkomponente (4 GPUs, 15 CPU-Kerne, 25000 MB) → Gültig
- 2 Amazon Nova Micro-Inferenzkomponenten (insgesamt 8 GPUs, 30 CPU-Kerne, 50000 MB) → Gültig (passt in die Instance-Kapazität)

- 1 Nova 2 Lite-Inferenzkomponente (4 GPUs, 20 CPU-Kerne, 100000 MB) → Gültig
- 2 Nova 2 Lite-Inferenzkomponenten (insgesamt 8 GPUs, 40 CPU-Kerne, 200000 MB) → Gültig
- 3 Amazon Nova Micro-Inferenzkomponenten (insgesamt 12 GPUs) → Abgelehnt (mehr als 8 verfügbare GPUs)

## Unterstützt AWS Regionen

In der folgenden Tabelle sind die AWS Regionen aufgeführt, in denen Amazon Nova-Modelle auf SageMaker Inferenz verfügbar sind:

| Name der Region         | Regionscode | Verfügbarkeit         |
|-------------------------|-------------|-----------------------|
| USA Ost (Nord-Virginia) | us-east-1   | Available (Verfügbar) |
| USA West (Oregon)       | us-west-2   | Available (Verfügbar) |

## Unterstützte Container-Images

In der folgenden Tabelle sind die Container-Image-URLs für Amazon Nova-Modelle nach SageMaker Inferenz nach Regionen aufgeführt. Das SM-Inference-latest Tag zeigt derzeit auf. v1.4

| Region    | Container-Image-URLs                                                                     |
|-----------|------------------------------------------------------------------------------------------|
| us-east-1 | 708977205387.dkr.ecr.us-east-1.amazonaws.com/<br>nova-inference-repo:SM-Inference-latest |
| us-west-2 | 176779409107.dkr.ecr.us-west-2.amazonaws.com/<br>nova-inference-repo:SM-Inference-latest |

## Bewährte Methoden

Bewährte Methoden für die Bereitstellung und Verwaltung von Modellen auf SageMaker finden Sie unter [Bewährte Methoden für SageMaker](#).



# Support

Bei Problemen und Support mit Amazon Nova-Modellen auf SageMaker Inferenz wenden Sie sich über die Konsole oder Ihren AWS Kundenbetreuer an den AWS Support.

## Themen

- [Erste Schritte](#)
- [Funktionen des Inferenzcontainers](#)
- [API-Referenz](#)
- [Einsatz von Amazon Nova Forge-Modellen bei der Missbrauchserkennung von Amazon SageMaker Inference](#)

## Erste Schritte

In diesem Handbuch erfahren Sie, wie Sie maßgeschneiderte Amazon Nova-Modelle auf SageMaker Echtzeit-Endpunkten bereitstellen, Inferenzparameter konfigurieren und Ihre Modelle zu Testzwecken aufrufen.

## Voraussetzungen

Die folgenden Voraussetzungen müssen erfüllt sein, um Amazon Nova-Modelle auf Basis von SageMaker Inferenz bereitzustellen:

- Erstellen Sie ein AWS-Konto — Falls Sie noch keines haben, finden Sie weitere Informationen unter [AWS Konto erstellen](#).
- Erforderliche IAM-Berechtigungen — Stellen Sie sicher, dass Ihrem IAM-Benutzer oder Ihrer IAM-Rolle die folgenden verwalteten Richtlinien zugeordnet sind:
  - `AmazonSageMakerFullAccess`
  - `AmazonS3FullAccess`
- Erforderliche SDKs/CLI Versionen — Die folgenden SDK-Versionen wurden mit Amazon Nova-Modellen auf SageMaker Inferenz getestet und validiert:
  - SageMaker Python SDK v3.0.0+ (`sagemaker>=3.0.0`) für ressourcenbasierten API-Ansatz
  - Boto3 Version 1.35.0+ (`boto3>=1.35.0`) für direkte API-Aufrufe. Die Beispiele in diesem Handbuch verwenden diesen Ansatz.
- Erhöhung des Servicekontingents — Fordern Sie eine Erhöhung des Amazon SageMaker Service-Kontingents für den ML-Instance-Typ an, den Sie für Ihren SageMaker Inference-

Endpoint verwenden möchten (z. B. `ml.p5.48xlarge` for endpoint usage). Eine Liste mit unterstützten Instance-Typen finden Sie unter [the section called “Unterstützte Modelle und Instanzen”](#). Informationen zur Beantragung einer Erhöhung finden Sie unter [Eine Erhöhung des Kontingents beantragen](#). Informationen zu SageMaker Instanzkontingenten finden Sie unter [SageMaker Endpunkte und Kontingente](#).

#### Tip

Für eine schnelle Komplettbereitstellung können Sie das [Custom Nova Model SageMaker Inference Notebook](#) ausführen, um ein benutzerdefiniertes Amazon Nova-Modell auf SageMaker Inferenz in einem einzigen Notebook bereitzustellen.

## Schritt 1: Anmeldeinformationen konfigurieren AWS

Konfigurieren Sie Ihre AWS Anmeldeinformationen mit einer der folgenden Methoden:

### Option 1: AWS CLI (Empfohlen)

```
aws configure
```

Geben Sie Ihren AWS Zugriffsschlüssel, Ihren geheimen Schlüssel und Ihre Standardregion ein, wenn Sie dazu aufgefordert werden.

### Option 2: Datei mit den AWS Anmeldeinformationen

Erstellen oder bearbeiten `~/.aws/credentials`:

```
[default]
aws_access_key_id = YOUR_ACCESS_KEY
aws_secret_access_key = YOUR_SECRET_KEY
```

### Option 3: Umgebungsvariablen

```
export AWS_ACCESS_KEY_ID=your_access_key
export AWS_SECRET_ACCESS_KEY=your_secret_key
```

 Note

Weitere Informationen zu AWS Anmeldeinformationen finden Sie unter [Konfiguration und Einstellungen für Anmeldeinformationsdateien](#).

## Clients initialisieren AWS

Erstellen Sie ein Python-Skript oder ein Notizbuch mit dem folgenden Code, um das AWS SDK zu initialisieren und Ihre Anmeldeinformationen zu überprüfen:

```
import boto3

AWS Configuration - Update these for your environment
REGION = "us-east-1" # Supported regions: us-east-1, us-west-2
AWS_ACCOUNT_ID = "YOUR_ACCOUNT_ID" # Replace with your AWS account ID

Initialize AWS clients using default credential chain
sagemaker = boto3.client('sagemaker', region_name=REGION)
sts = boto3.client('sts')

Verify credentials
try:
 identity = sts.get_caller_identity()
 print(f"Successfully authenticated to AWS Account: {identity['Account']}")

 if identity['Account'] != AWS_ACCOUNT_ID:
 print(f"Warning: Connected to account {identity['Account']}, expected {AWS_ACCOUNT_ID}")

except Exception as e:
 print(f"Failed to authenticate: {e}")
 print("Please verify your credentials are configured correctly.")
```

Wenn die Authentifizierung erfolgreich ist, sollten Sie eine Ausgabe sehen, die Ihre AWS Konto-ID bestätigt.

## Schritt 2: Erstellen Sie eine SageMaker Ausführungsrolle

Eine SageMaker Ausführungsrolle ist eine IAM-Rolle, die SageMaker Berechtigungen für den Zugriff auf AWS Ressourcen in Ihrem Namen gewährt, z. B. Amazon S3 S3-Buckets für Modellartefakte und CloudWatch für die Protokollierung.

## Die Ausführungsrolle erstellen

### Note

Für die Erstellung von IAM-Rollen sind `iam:AttachRolePolicy` Berechtigungen erforderlich `iam:CreateRole`. Stellen Sie sicher, dass Ihr IAM-Benutzer oder Ihre IAM-Rolle über diese Berechtigungen verfügt, bevor Sie fortfahren.

Der folgende Code erstellt eine IAM-Rolle mit den erforderlichen Berechtigungen für die Bereitstellung benutzerdefinierter Amazon Nova-Modelle:

```
import json

Create SageMaker Execution Role
role_name = f"SageMakerInference-ExecutionRole-{AWS_ACCOUNT_ID}"

trust_policy = {
 "Version": "2012-10-17",
 "Statement": [
 {
 "Effect": "Allow",
 "Principal": {"Service": "sagemaker.amazonaws.com"},
 "Action": "sts:AssumeRole"
 }
]
}

iam = boto3.client('iam', region_name=REGION)

Create the role
role_response = iam.create_role(
 RoleName=role_name,
 AssumeRolePolicyDocument=json.dumps(trust_policy),
 Description='SageMaker execution role with S3 and SageMaker access'
)

Attach required policies
iam.attach_role_policy(
 RoleName=role_name,
 PolicyArn='arn:aws:iam::aws:policy/AmazonSageMakerFullAccess'
)
```

```
iam.attach_role_policy(
 RoleName=role_name,
 PolicyArn='arn:aws:iam::aws:policy/AmazonS3FullAccess'
)

SAGEMAKER_EXECUTION_ROLE_ARN = role_response['Role']['Arn']
print(f"Created SageMaker execution role: {SAGEMAKER_EXECUTION_ROLE_ARN}")
```

### Verwenden einer vorhandenen Ausführungsrolle (optional)

Wenn Sie bereits über eine SageMaker Ausführungsrolle verfügen, können Sie diese stattdessen verwenden:

```
Replace with your existing role ARN
SAGEMAKER_EXECUTION_ROLE_ARN = "arn:aws:iam::YOUR_ACCOUNT_ID:role/
YOUR_EXISTING_ROLE_NAME"
```

So finden Sie bestehende SageMaker Rollen in Ihrem Konto:

```
iam = boto3.client('iam', region_name=REGION)
response = iam.list_roles()
sagemaker_roles = [role for role in response['Roles'] if 'SageMaker' in
 role['RoleName']]
for role in sagemaker_roles:
 print(f"{role['RoleName']}: {role['Arn']}")
```

#### Important

Die Ausführungsrolle muss über eine Vertrauensbeziehung zu Amazon S3 `sagemaker.amazonaws.com` und SageMaker Ressourcen verfügen und über Zugriffsberechtigungen verfügen.

Weitere Informationen zu SageMaker Ausführungsrollen finden Sie unter [SageMaker Rollen](#).

## Schritt 3: Modellparameter konfigurieren

Konfigurieren Sie die Bereitstellungsparameter für Ihr Amazon Nova-Modell. Diese Einstellungen steuern das Modellverhalten, die Ressourcenzuweisung und die Inferenzmerkmale. Eine Liste

der unterstützten Instanztypen und der jeweils unterstützten Werte für `CONTEXT_LENGTH` und `MAX_CONCURRENCY` finden Sie unter. [the section called “Unterstützte Modelle und Instanzen”](#)  
Eine vollständige Liste zusätzlicher Container-Funktionen wie Sampling-Standardwerte, spekulative Dekodierung und Quantisierung finden Sie unter. [the section called “Funktionen des Containers”](#)

### Erforderliche Parameter

- **IMAGE:** Die Docker-Container-Image-URI für den Amazon Nova-Inferenzcontainer. Dies wird bereitgestellt von. AWS
- **CONTEXT\_LENGTH:** Länge des Modellkontextes.
- **MAX\_CONCURRENCY:** Maximale Anzahl von Sequenzen pro Iteration; legt die Grenze fest, wie viele einzelne Benutzeranfragen (Eingabeaufforderungen) gleichzeitig innerhalb eines einzelnen Batches auf der GPU verarbeitet werden können. Bereich: Ganzzahl größer als 0.

### Konfigurieren Sie Ihre Bereitstellung

```
AWS Configuration
REGION = "us-east-1" # Must match region from Step 1

ECR Account mapping by region
ECR_ACCOUNT_MAP = {
 "us-east-1": "708977205387",
 "us-west-2": "176779409107"
}

Container Image
IMAGE = f"{ECR_ACCOUNT_MAP[REGION]}.dkr.ecr.{REGION}.amazonaws.com/nova-inference-
repo:SM-Inference-latest"
print(f"IMAGE = {IMAGE}")

Required parameters
CONTEXT_LENGTH = "16000" # Maximum total context length
MAX_CONCURRENCY = "2" # Maximum concurrent sequences

Build environment variables for the container
environment = {
 'CONTEXT_LENGTH': CONTEXT_LENGTH,
 'MAX_CONCURRENCY': MAX_CONCURRENCY,
 # Optional: add container feature environment variables here.
 # See "Inference Container Features" for the full list.
 # Examples:
```

```
'DEFAULT_TEMPERATURE': '0.7',
'DEFAULT_MAX_NEW_TOKENS': '512',
'QUANTIZATION_DTYPE': 'fp8',
}

print("Environment configuration:")
for key, value in environment.items():
 print(f" {key}: {value}")
```

Konfigurieren Sie bereitstellungsspezifische Parameter

Konfigurieren Sie jetzt die spezifischen Parameter für Ihre Amazon Nova-Modellbereitstellung, einschließlich des Standorts der Modellartefakte und der Auswahl des Instance-Typs.

Legen Sie die Bereitstellungs-ID fest

```
Deployment identifier - use a descriptive name for your use case
JOB_NAME = "my-nova-deployment"
```

Geben Sie den Speicherort der Modellartefakte

Geben Sie die Amazon S3 S3-URI an, in der Ihre trainierten Amazon Nova-Modellartefakte gespeichert sind. Dies sollte der Ausgabeort für Ihr Modelltraining oder Ihre Feinabstimmung sein.

```
S3 location of your trained Nova model artifacts
Replace with your model's S3 URI - must end with /
MODEL_S3_LOCATION = "s3://your-bucket-name/path/to/model/artifacts/"
```

Wählen Sie die Modellvariante und den Instanztyp aus

```
Configure model variant and instance type
TESTCASE = {
 "model": "lite2", # Options: micro, lite, lite2
 "instance": "ml.p5.48xlarge" # Refer to "Supported models and instances" section
}

Generate resource names
INSTANCE_TYPE = TESTCASE["instance"]
MODEL_NAME = JOB_NAME + "-" + TESTCASE["model"] + "-" + INSTANCE_TYPE.replace(".", "-")
ENDPOINT_CONFIG_NAME = MODEL_NAME + "-Config"
ENDPOINT_NAME = MODEL_NAME + "-Endpoint"
```

```
print(f"Model Name: {MODEL_NAME}")
print(f"Endpoint Config: {ENDPOINT_CONFIG_NAME}")
print(f"Endpoint Name: {ENDPOINT_NAME}")
```

## Benennungskonventionen

Der Code generiert automatisch konsistente Namen für AWS Ressourcen:

- Modellname: {JOB\_NAME}-{model}-{instance-type}
- Endpunktkonfiguration: {MODEL\_NAME}-Config
- Name des Endpunkts: {MODEL\_NAME}-Endpoint

## Schritt 4: SageMaker Ressourcen erstellen und den Endpunkt bereitstellen

SageMaker bietet zwei Ansätze für die Bereitstellung von Modellen auf Echtzeit-Endpunkten. Wählen Sie den Ansatz, der zu Ihrem Anwendungsfall passt:

- Inferenzkomponenten (empfohlen): Stellt Modelle als Inferenzkomponenten auf einem Endpunkt bereit. Dieser Ansatz ermöglicht es Ihnen, mehrere Modelle auf einem einzigen Endpunkt zu hosten, Modelle unabhängig voneinander zu skalieren und die Ressourcennutzung zu optimieren.
- Endpunkte mit einem einzigen Modell: Stellt mithilfe eines Modellobjekts und einer Endpunktkonfiguration ein einzelnes Modell direkt auf einem Endpunkt bereit. Dieser Ansatz ist einfacher einzurichten und eignet sich für Entwicklungs-, Test- oder Workloads, für die nur ein Modell pro Endpunkt erforderlich ist.

### Option A: Erstellen mit Inferenzkomponenten

Bei Inferenzkomponenten erstellen Sie zuerst einen Endpunkt und stellen dann Ihr Modell als Inferenzkomponente auf diesem Endpunkt bereit. Dadurch wird das Modell von der Endpunktinfrastruktur entkoppelt, was Ihnen mehr Flexibilität bietet.

### Erstellen Sie die Endpunktkonfiguration

Erstellen Sie eine Endpunktkonfiguration, die die Infrastruktur definiert, ohne ein Modell anzugeben. Der Instanztyp und die Anzahl der Instanzen werden auf Endpunktebene verwaltet:

```
Create Endpoint Configuration for inference components
INFERENCE_COMPONENT_NAME = MODEL_NAME + "-IC"
```



```

try:
 config_response = sagemaker.create_endpoint_config(
 EndpointConfigName=ENDPOINT_CONFIG_NAME,
 ProductionVariants=[
 {
 'VariantName': 'primary',
 'InstanceType': INSTANCE_TYPE,
 'InitialInstanceCount': 1,
 'RoutingConfig': {
 'RoutingStrategy': 'LEAST_OUTSTANDING_REQUESTS'
 }
 }
],
 Tags=[
 {
 'Key': 'sagemaker:nova-inference-component',
 'Value': 'true'
 }
]
)
 print("Endpoint configuration created successfully!")
 print(f"Config ARN: {config_response['EndpointConfigArn']}")

except sagemaker.exceptions.ClientError as e:
 print(f"Error creating endpoint configuration: {e}")

```

## Den Endpunkt erstellen und bereitstellen

```

import time

try:
 endpoint_response = sagemaker.create_endpoint(
 EndpointName=ENDPOINT_NAME,
 EndpointConfigName=ENDPOINT_CONFIG_NAME
)
 print("Endpoint creation initiated successfully!")
 print(f"Endpoint ARN: {endpoint_response['EndpointArn']}")
except Exception as e:
 print(f"Error creating endpoint: {e}")

Wait for endpoint to be InService
print("Waiting for endpoint to be InService...")
print("This typically takes 5-10 minutes...\n")

```

```

while True:
 try:
 response = sagemaker.describe_endpoint(EndpointName=ENDPOINT_NAME)
 status = response['EndpointStatus']

 if status == 'Creating':
 print(f"# Status: {status} - Provisioning infrastructure...")
 elif status == 'InService':
 print(f"# Status: {status}")
 print(f"\nEndpoint '{ENDPOINT_NAME}' is ready.")
 break
 elif status == 'Failed':
 print(f"# Status: {status}")
 print(f"Failure Reason: {response.get('FailureReason', 'Unknown')}")
 break
 else:
 print(f"Status: {status}")
 except Exception as e:
 print(f"Error checking endpoint status: {e}")
 break

 time.sleep(30)

```

## Erstellen Sie die Inferenzkomponente

Sobald der Endpunkt fertig ist InService, stellen Sie Ihr Amazon Nova-Modell als Inferenzkomponente bereit:

```

try:
 ic_response = sagemaker.create_inference_component(
 InferenceComponentName=INFERENCE_COMPONENT_NAME,
 EndpointName=ENDPOINT_NAME,
 VariantName='primary',
 Specification={
 'Container': {
 'Image': IMAGE,
 'ArtifactUrl': MODEL_S3_LOCATION,
 'Environment': environment
 },
 'ComputeResourceRequirements': {
 'NumberOfCpuCoresRequired': 15,
 'NumberOfAcceleratorDevicesRequired': 4,

```

```

 'MinMemoryRequiredInMb': 25000
 },
 RuntimeConfig={
 'CopyCount': 1
 }
)
print("Inference component creation initiated!")
print(f"Inference Component ARN: {ic_response['InferenceComponentArn']}")

except sagemaker.exceptions.ClientError as e:
 print(f"Error creating inference component: {e}")

```

### Hauptparameter:

- **InferenceComponentName:** Eindeutiger Bezeichner für Ihre Inferenzkomponente
- **EndpointName:** Der Endpunkt, auf dem die Komponente bereitgestellt werden soll
- **Image:** Docker-Container-Image-URI für Amazon Nova-Inferenz
- **ArtifactUrl:** Amazon S3 S3-Standort Ihrer Modellartefakte
- **Environment:** In Schritt 3 konfigurierte Umgebungsvariablen
- **NumberOfCpuCoresRequired:** Anzahl der pro Modellkopie benötigten CPU-Kerne
- **NumberOfAcceleratorDevicesRequired:** Anzahl der pro Modellkopie benötigten Beschleunigergeräte (GPUs)
- **MinMemoryRequiredInMb:** Pro Modellkopie ist mindestens Speicherplatz in MB erforderlich
- **CopyCount:** Anzahl der bereitzustellenden Modellkopien

### Überwachen Sie die Bereitstellung von Inferenzkomponenten

```

Wait for inference component to be InService
print("Waiting for inference component deployment...")
print("This typically takes 10-20 minutes as the model is loaded...\n")

while True:
 try:
 ic_desc = sagemaker.describe_inference_component(
 InferenceComponentName=INFERENCE_COMPONENT_NAME
)
 ic_status = ic_desc['InferenceComponentStatus']
 except sagemaker.exceptions.ClientError as e:
 print(f"Error describing inference component: {e}")

```

```

 if ic_status == 'Creating':
 print(f"# Status: {ic_status} - Loading model artifacts...")
 elif ic_status == 'InService':
 print(f"# Status: {ic_status}")
 print(f"\nInference component '{INFERENCE_COMPONENT_NAME}' is ready!")
 break
 elif ic_status == 'Failed':
 print(f"# Status: {ic_status}")
 print(f"Failure Reason: {ic_desc.get('FailureReason', 'Unknown')}")
 break
 else:
 print(f"Status: {ic_status}")
except Exception as e:
 print(f"Error checking inference component status: {e}")
 break

time.sleep(30)

```

### Note

Wenn Sie den Endpunkt in Schritt 5 aufrufen, müssen Sie den `InferenceComponentName` Parameter in Ihre Aufruf-Aufrufe aufnehmen. Einzelheiten finden Sie in Schritt 5.

## Option B: Endpunkte mit einem einzigen Modell erstellen

Bei Einzelmodell-Endpunkten erstellen Sie ein SageMaker Modellobjekt, eine Endpunktconfiguration und stellen dann den Endpunkt bereit. Bei diesem Ansatz wird das Modell direkt in die Endpunktconfiguration gepackt.

### Erstellen Sie das SageMaker Modell

Der folgende Code erstellt ein SageMaker Modell, das auf Ihre Amazon Nova-Modellartefakte verweist:

```

try:
 model_response = sagemaker.create_model(
 ModelName=MODEL_NAME,
 PrimaryContainer={
 'Image': IMAGE,
 'ModelDataSource': {
 'S3DataSource': {

```

```

 'S3Uri': MODEL_S3_LOCATION,
 'S3DataType': 'S3Prefix',
 'CompressionType': 'None'
 }
},
 'Environment': environment
},
 ExecutionRoleArn=SAGEMAKER_EXECUTION_ROLE_ARN,
 EnableNetworkIsolation=True
)
print("Model created successfully!")
print(f"Model ARN: {model_response['ModelArn']}")

except sagemaker.exceptions.ClientError as e:
 print(f"Error creating model: {e}")

```

### Hauptparameter:

- **ModelName:** Eindeutiger Bezeichner für Ihr Modell
- **Image:** Docker-Container-Image-URI für Amazon Nova-Inferenz
- **ModelDataSource:** Amazon S3 S3-Standort Ihrer Modellartefakte
- **Environment:** In Schritt 3 konfigurierte Umgebungsvariablen
- **ExecutionRoleArn:** IAM-Rolle aus Schritt 2
- **EnableNetworkIsolation:** Aus Sicherheitsgründen auf True setzen (verhindert, dass der Container ausgehende Netzwerkanrufe tätigt)

### Erstellen Sie die Endpunktkonfiguration

Erstellen Sie als Nächstes eine Endpunktkonfiguration, die Ihre Bereitstellungsinfrastruktur definiert:

```

Create Endpoint Configuration
try:
 production_variant = {
 'VariantName': 'primary',
 'ModelName': MODEL_NAME,
 'InitialInstanceCount': 1,
 'InstanceType': INSTANCE_TYPE,
 }

 config_response = sagemaker.create_endpoint_config(

```

```

 EndpointConfigName=ENDPOINT_CONFIG_NAME,
 ProductionVariants=[production_variant]
)
 print("Endpoint configuration created successfully!")
 print(f"Config ARN: {config_response['EndpointConfigArn']}")

except sagemaker.exceptions.ClientError as e:
 print(f"Error creating endpoint configuration: {e}")

```

### Hauptparameter:

- **VariantName:** Identifier für diese Modellvariante (verwenden Sie „primary“ für Implementierungen mit nur einem Modell)
- **ModelName:** Verweist auf das oben erstellte Modell
- **InitialInstanceCount:** Anzahl der bereitzustellenden Instanzen (beginnen Sie mit 1, skalieren Sie bei Bedarf später)
- **InstanceType:** In Schritt 3 ausgewählter ML-Instanztyp

### Stellen Sie den Endpunkt bereit

```

import time

try:
 endpoint_response = sagemaker.create_endpoint(
 EndpointName=ENDPOINT_NAME,
 EndpointConfigName=ENDPOINT_CONFIG_NAME
)
 print("Endpoint creation initiated successfully!")
 print(f"Endpoint ARN: {endpoint_response['EndpointArn']}")
except Exception as e:
 print(f"Error creating endpoint: {e}")

```

### Überwachen Sie die Endpunktentwicklung

Der folgende Code fragt den Endpunktstatus ab, bis die Bereitstellung abgeschlossen ist:

```

Monitor endpoint creation progress
print("Waiting for endpoint creation to complete...")
print("This typically takes 15-30 minutes...\n")

```

```

while True:
 try:
 response = sagemaker.describe_endpoint(EndpointName=ENDPOINT_NAME)
 status = response['EndpointStatus']

 if status == 'Creating':
 print(f"# Status: {status} - Provisioning infrastructure and loading
model...")
 elif status == 'InService':
 print(f"# Status: {status}")
 print("\nEndpoint creation completed successfully!")
 print(f"Endpoint Name: {ENDPOINT_NAME}")
 print(f"Endpoint ARN: {response['EndpointArn']}")
 break
 elif status == 'Failed':
 print(f"# Status: {status}")
 print(f"Failure Reason: {response.get('FailureReason', 'Unknown')}")
 print("\nFull response:")
 print(response)
 break
 else:
 print(f"Status: {status}")

 except Exception as e:
 print(f"Error checking endpoint status: {e}")
 break

 time.sleep(30) # Check every 30 seconds

```

## Überprüfen Sie die Ressourcenerstellung

Sie können überprüfen, ob Ihre Ressourcen erfolgreich erstellt wurden:

```

Describe the model
model_info = sagemaker.describe_model(ModelName=MODEL_NAME)
print(f"Model Status: {model_info['ModelName']} created")

Describe the endpoint configuration
config_info =
 sagemaker.describe_endpoint_config(EndpointConfigName=ENDPOINT_CONFIG_NAME)
print(f"Endpoint Config Status: {config_info['EndpointConfigName']} created")

```

## Überprüfen Sie, ob der Endpunkt bereit ist

Unabhängig davon, welchen Ansatz Sie gewählt haben, können Sie die Endpunktkonfiguration überprüfen:

```
Get detailed endpoint information
endpoint_info = sagemaker.describe_endpoint(EndpointName=ENDPOINT_NAME)

print("\n=== Endpoint Details ===")
print(f"Endpoint Name: {endpoint_info['EndpointName']}")
print(f"Endpoint ARN: {endpoint_info['EndpointArn']}")
print(f"Status: {endpoint_info['EndpointStatus']}")
print(f"Creation Time: {endpoint_info['CreationTime']}")
print(f>Last Modified: {endpoint_info['LastModifiedTime']}")

Get endpoint config for instance type details
endpoint_config_name = endpoint_info['EndpointConfigName']
endpoint_config =
 sagemaker.describe_endpoint_config(EndpointConfigName=endpoint_config_name)

Display production variant details
for variant in endpoint_info['ProductionVariants']:
 print(f"\nProduction Variant: {variant['VariantName']}")
 print(f" Current Instance Count: {variant['CurrentInstanceCount']}")
 print(f" Desired Instance Count: {variant['DesiredInstanceCount']}")
 # Get instance type from endpoint config
 for config_variant in endpoint_config['ProductionVariants']:
 if config_variant['VariantName'] == variant['VariantName']:
 print(f" Instance Type: {config_variant['InstanceType']}")
 break
```

## Behebung von Fehlern bei der Endpunkterstellung

### Häufige Fehlerursachen:

- Unzureichende Kapazität: Der angeforderte Instance-Typ ist in Ihrer Region nicht verfügbar
  - Lösung: Probieren Sie einen anderen Instance-Typ aus oder fordern Sie eine Erhöhung des Kontingents an
- IAM-Berechtigungen: Der Ausführungsrolle fehlen die erforderlichen Berechtigungen
  - Lösung: Stellen Sie sicher, dass die Rolle Zugriff auf Amazon S3 S3-Modellartefakte und die erforderlichen SageMaker Berechtigungen hat
- Modellartefakte wurden nicht gefunden: Die Amazon S3 S3-URI ist falsch oder es kann nicht darauf zugegriffen werden



- Lösung: Überprüfen Sie die Amazon S3 S3-URI und überprüfen Sie die Bucket-Berechtigungen. Stellen Sie sicher, dass Sie sich in der richtigen Region befinden
- Ressourcenlimits: Die Kontolimits für Endpunkte oder Instances wurden überschritten
- Lösung: Beantragen Sie eine Erhöhung des Servicekontingents über Service Quotas oder AWS Support

#### Note

Wenn Sie einen ausgefallenen Endpunkt löschen und von vorne beginnen müssen:

```
sagemaker.delete_endpoint(EndpointName=ENDPOINT_NAME)
```

## Schritt 5: Rufen Sie den Endpunkt auf

Sobald Ihr Endpunkt da ist InService, können Sie Inferenzanfragen senden, um Prognosen aus Ihrem Amazon Nova-Modell zu generieren. SageMaker unterstützt synchrone Endpunkte (Echtzeit mit streaming/non Streaming-Modi) und asynchrone Endpunkte (Amazon S3-based für Batch-Verarbeitung).

Richten Sie den Runtime-Client ein

Erstellen Sie einen SageMaker Runtime-Client mit den entsprechenden Timeout-Einstellungen:

```
import json
import boto3
import botocore
from botocore.exceptions import ClientError

Configure client with appropriate timeouts
config = botocore.config.Config(
 read_timeout=120, # Maximum time to wait for response
 connect_timeout=10, # Maximum time to establish connection
 retries={'max_attempts': 3} # Number of retry attempts
)

Create SageMaker Runtime client
runtime_client = boto3.client('sagemaker-runtime', config=config, region_name=REGION)
```

## Erstellen Sie eine universelle Inferenzfunktion

Die folgende Funktion verarbeitet sowohl Streaming- als auch Nicht-Streaming-Anfragen. Sie verwendet die in Schritt 4 definierte `INFERENCE_COMPONENT_NAME` Variable. Wenn Sie die Implementierung mithilfe von Inferenzkomponenten (Option A) durchgeführt haben, wurde diese Einstellung auf `MODEL_NAME + "-IC"` gesetzt. Wenn Sie die Bereitstellung mit Einzelmodell-Endpunkten (Option B) durchgeführt haben, wurde dies nicht definiert. Stellen Sie es daher auf ein, `None` bevor Sie diesen Schritt ausführen:

```
Only needed if you followed Option B (single model endpoints) in Step 4:
INFERENCE_COMPONENT_NAME = None

def invoke_nova_endpoint(request_body):
 """
 Invoke Nova endpoint with automatic streaming detection.
 Supports both inference component and single model endpoint deployments.

 Args:
 request_body (dict): Request payload containing prompt and parameters

 Returns:
 dict: Response from the model (for non-streaming requests)
 None: For streaming requests (prints output directly)
 """
 body = json.dumps(request_body)
 is_streaming = request_body.get("stream", False)

 # Build invoke parameters
 invoke_params = {
 'EndpointName': ENDPOINT_NAME,
 'ContentType': 'application/json',
 'Body': body
 }

 # Add InferenceComponentName if using inference components
 if INFERENCE_COMPONENT_NAME:
 invoke_params['InferenceComponentName'] = INFERENCE_COMPONENT_NAME

 try:
 print(f"Invoking endpoint ({'streaming' if is_streaming else 'non-streaming'})...")

 if is_streaming:
```

```

 response =
runtime_client.invoke_endpoint_with_response_stream(**invoke_params)

 event_stream = response['Body']
 for event in event_stream:
 if 'PayloadPart' in event:
 chunk = event['PayloadPart']
 if 'Bytes' in chunk:
 data = chunk['Bytes'].decode()
 print("Chunk:", data)
 else:
 # Non-streaming inference
 invoke_params['Accept'] = 'application/json'
 response = runtime_client.invoke_endpoint(**invoke_params)

 response_body = response['Body'].read().decode('utf-8')
 result = json.loads(response_body)
 print("# Response received successfully")
 return result

except ClientError as e:
 error_code = e.response['Error']['Code']
 error_message = e.response['Error']['Message']
 print(f"# AWS Error: {error_code} - {error_message}")
except Exception as e:
 print(f"# Unexpected error: {str(e)}")

```

## Beispiel 1: Abschluss des Non-streaming Chats

Verwenden Sie das Chat-Format für Konversationsinteraktionen:

```

Non-streaming chat request
chat_request = {
 "messages": [
 {"role": "user", "content": "Hello! How are you?"}
],
 "max_tokens": 100,
 "max_completion_tokens": 100, # Alternative to max_tokens
 "stream": False,
 "temperature": 0.7,
 "top_p": 0.9,
 "top_k": 50,
 "logprobs": True,
 "top_logprobs": 3,
}

```

```

 "reasoning_effort": "low", # Options: "low", "high"
 "allowed_token_ids": None, # List of allowed token IDs
 "truncate_prompt_tokens": None, # Truncate prompt to this many tokens
 "stream_options": None
}

response = invoke_nova_endpoint(chat_request)

```

### Beispielantwort:

```

{
 "id": "chatcmpl-123456",
 "object": "chat.completion",
 "created": 1234567890,
 "model": "default",
 "choices": [
 {
 "index": 0,
 "message": {
 "role": "assistant",
 "content": "Hello! I'm doing well, thank you for asking. I'm here and ready to help you with any questions or tasks you might have. How can I assist you today?"
 },
 "logprobs": {
 "content": [
 {
 "token": "Hello",
 "logprob": -0.123,
 "top_logprobs": [
 {"token": "Hello", "logprob": -0.123},
 {"token": "Hi", "logprob": -2.456},
 {"token": "Hey", "logprob": -3.789}
]
 }
 # Additional tokens...
]
 },
 "finish_reason": "stop"
 }
],
 "usage": {
 "prompt_tokens": 12,

```

```

 "completion_tokens": 28,
 "total_tokens": 40
 }
}

```

## Beispiel 2: Einfache Textvervollständigung

Verwenden Sie das Vervollständigungsformat für die einfache Textgenerierung:

```

Simple completion request
completion_request = {
 "prompt": "The capital of France is",
 "max_tokens": 50,
 "stream": False,
 "temperature": 0.0,
 "top_p": 1.0,
 "top_k": -1, # -1 means no limit
 "logprobs": 3, # Number of log probabilities to return
 "allowed_token_ids": None, # List of allowed token IDs
 "truncate_prompt_tokens": None, # Truncate prompt to this many tokens
 "stream_options": None
}

response = invoke_nova_endpoint(completion_request)

```

## Beispielantwort:

```

{
 "id": "cmpl-789012",
 "object": "text_completion",
 "created": 1234567890,
 "model": "default",
 "choices": [
 {
 "text": " Paris.",
 "index": 0,
 "logprobs": {
 "tokens": [" Paris", "."],
 "token_logprobs": [-0.001, -0.002],
 "top_logprobs": [
 {" Paris": -0.001, " London": -5.234, " Rome": -6.789},
 {".": -0.002, ",": -4.567, " ": -7.890}
]
 }
 }
]
}

```

```

 },
 "finish_reason": "stop"
 }
],
"usage": {
 "prompt_tokens": 6,
 "completion_tokens": 2,
 "total_tokens": 8
}
}

```

### Beispiel 3: Abschluss des Streaming-Chats

```

Streaming chat request
streaming_request = {
 "messages": [
 {"role": "user", "content": "Tell me a short story about a robot"}
],
 "max_tokens": 200,
 "stream": True,
 "temperature": 0.7,
 "top_p": 0.95,
 "top_k": 40,
 "logprobs": True,
 "top_logprobs": 2,
 "reasoning_effort": "high", # For more detailed reasoning
 "stream_options": {"include_usage": True}
}

invoke_nova_endpoint(streaming_request)

```

### Beispiel für eine Streaming-Ausgabe:

```

Chunk: data: {"id":"chatcmpl-029ca032-fa01-4868-80b7-
c4cb1af90fb9","object":"chat.completion.chunk","created":1772060532,"model":"default","choices"
[{"index":0,"delta":
{"role":"assistant","content":"","reasoning_content":null},"logprobs":null,"finish_reason":null}
Chunk: data: {"id":"chatcmpl-029ca032-fa01-4868-80b7-
c4cb1af90fb9","object":"chat.completion.chunk","created":1772060532,"model":"default","choices"
[{"index":0,"delta":{"content":" Once","reasoning_content":null},"logprobs":
{"content":[{"token":"\u2581once","logprob":-0.6078429222106934,"bytes":
[226,150,129,79,110,99,101],"top_logprobs":
[{"token":"\u2581once","logprob":-0.6078429222106934,"bytes":

```

```
[226,150,129,79,110,99,101]},{ "token": "\u2581In", "logprob": -0.7864127159118652, "bytes":
[226,150,129,73,110]}}]}], "finish_reason": null, "token_ids": null}}]
Chunk: data: {"id": "chatcmpl-029ca032-fa01-4868-80b7-
c4cb1af90fb9", "object": "chat.completion.chunk", "created": 1772060532, "model": "default", "choices":
[{"index": 0, "delta": {"content": " upon", "reasoning_content": null}, "logprobs":
{"content": [{"token": "\u2581upon", "logprob": -0.0012345, "bytes":
[226,150,129,117,112,111,110], "top_logprobs":
[{"token": "\u2581upon", "logprob": -0.0012345, "bytes": [226,150,129,117,112,111,110]},
{"token": "\u2581a", "logprob": -6.789, "bytes":
[226,150,129,97]}]}]}], "finish_reason": null, "token_ids": null}}]
Chunk: data: {"id": "chatcmpl-029ca032-fa01-4868-80b7-
c4cb1af90fb9", "object": "chat.completion.chunk", "created": 1772060532, "model": "default", "choices":
[{"index": 0, "delta": {"content": " a", "reasoning_content": null}, "logprobs":
{"content": [{"token": "\u2581a", "logprob": -0.0001234, "bytes":
[226,150,129,97], "top_logprobs": [{"token": "\u2581a", "logprob": -0.0001234, "bytes":
[226,150,129,97]}], {"token": "\u2581time", "logprob": -9.123, "bytes":
[226,150,129,116,105,109,101]}]}]}], "finish_reason": null, "token_ids": null}}]
Chunk: data: {"id": "chatcmpl-029ca032-fa01-4868-80b7-
c4cb1af90fb9", "object": "chat.completion.chunk", "created": 1772060532, "model": "default", "choices":
[{"index": 0, "delta": {"content": " time", "reasoning_content": null}, "logprobs":
{"content": [{"token": "\u2581time", "logprob": -0.0023456, "bytes":
[226,150,129,116,105,109,101], "top_logprobs":
[{"token": "\u2581time", "logprob": -0.0023456, "bytes": [226,150,129,116,105,109,101]},
{"token": "", "logprob": -6.012, "bytes":
[44]}]}]}], "finish_reason": null, "token_ids": null}}]

Additional chunks...

Chunk: data: {"id": "chatcmpl-029ca032-fa01-4868-80b7-
c4cb1af90fb9", "object": "chat.completion.chunk", "created": 1772060532, "model": "default", "choices":
[{"index": 0, "delta": {}, "logprobs": null, "finish_reason": "stop"}], "usage":
{"prompt_tokens": 15, "completion_tokens": 87, "total_tokens": 102}}
Chunk: data: [DONE]
```

#### Beispiel 4: Abschluss eines multimodalen Chats

Verwenden Sie das multimodale Format für Bild- und Texteingaben:

```
Multimodal chat request (if supported by your model)
multimodal_request = {
 "messages": [
 {
 "role": "user",
 "content": [
```

```

 {"type": "text", "text": "What's in this image?"},
 {"type": "image_url", "image_url": {"url": "data:image/
jpeg;base64,..."}}
]
}
],
"max_tokens": 150,
"temperature": 0.3,
"top_p": 0.8,
"stream": False
}

response = invoke_nova_endpoint(multimodal_request)

```

Beispielantwort:

```

{
 "id": "chatcmpl-345678",
 "object": "chat.completion",
 "created": 1234567890,
 "model": "default",
 "choices": [
 {
 "index": 0,
 "message": {
 "role": "assistant",
 "content": "The image shows..."
 },
 "finish_reason": "stop"
 }
],
 "usage": {
 "prompt_tokens": 1250,
 "completion_tokens": 45,
 "total_tokens": 1295
 }
}

```

## Schritt 6: Ressourcen bereinigen (optional)

Um unnötige Kosten zu vermeiden, löschen Sie die AWS Ressourcen, die Sie in diesem Tutorial erstellt haben. SageMaker Bei Endpunkten fallen Gebühren an, während sie laufen, auch wenn Sie nicht aktiv Inferenzanfragen stellen.



 Important

Das Löschen von Ressourcen ist dauerhaft und kann nicht rückgängig gemacht werden. Stellen Sie sicher, dass Sie diese Ressourcen nicht mehr benötigen, bevor Sie fortfahren.

## Initialisieren Sie den Cleanup-Client

```
import boto3
import time

Initialize SageMaker client
sagemaker = boto3.client('sagemaker', region_name=REGION)
```

## Löschen Sie die Inferenzkomponente (wenn Sie Option A verwenden)

Wenn Sie die Bereitstellung mithilfe von Inferenzkomponenten durchgeführt haben, löschen Sie zuerst die Inferenzkomponente, bevor Sie den Endpunkt löschen:

```
Delete inference component (Option A only)
try:
 print("Deleting inference component...")

 sagemaker.delete_inference_component(InferenceComponentName=INFERENCE_COMPONENT_NAME)
 print(f"# Inference component '{INFERENCE_COMPONENT_NAME}' deletion initiated")
except Exception as e:
 print(f"# Error deleting inference component: {e}")

Wait for inference component to be deleted before proceeding
print("Waiting for inference component deletion...")
while True:
 try:

 sagemaker.describe_inference_component(InferenceComponentName=INFERENCE_COMPONENT_NAME)
 time.sleep(10)
 except sagemaker.exceptions.ClientError as e:
 if e.response['Error']['Code'] == 'ValidationException':
 print("# Inference component successfully deleted")
 break
 else:
 print(f"Error: {e}")
```

```
break
```

## Löschen Sie den Endpunkt

```
try:
 print("Deleting endpoint...")
 sagemaker.delete_endpoint(EndpointName=ENDPOINT_NAME)
 print(f"# Endpoint '{ENDPOINT_NAME}' deletion initiated")
 print("Charges will stop once deletion completes (typically 2-5 minutes)")
except Exception as e:
 print(f"# Error deleting endpoint: {e}")
```

### Note

Das Löschen des Endpunkts erfolgt asynchron. Sie können den Löschstatus überwachen:

```
import time

print("Monitoring endpoint deletion...")
while True:
 try:
 response = sagemaker.describe_endpoint(EndpointName=ENDPOINT_NAME)
 status = response['EndpointStatus']
 print(f"Status: {status}")
 time.sleep(10)
 except sagemaker.exceptions.ClientError as e:
 if e.response['Error']['Code'] == 'ValidationException':
 print("# Endpoint successfully deleted")
 break
 else:
 print(f"Error: {e}")
 break
```

## Löschen Sie die Endpunktkonfiguration

Nachdem der Endpunkt gelöscht wurde, entfernen Sie die Endpunktkonfiguration:

```
try:
 print("Deleting endpoint configuration...")
 sagemaker.delete_endpoint_config(EndpointConfigName=ENDPOINT_CONFIG_NAME)
```

```
print(f"# Endpoint configuration '{ENDPOINT_CONFIG_NAME}' deleted")
except Exception as e:
 print(f"# Error deleting endpoint configuration: {e}")
```

Löschen Sie das Modell (nur Option B)

Wenn Sie Einzelmodell-Endpunkte verwendet haben, entfernen Sie das SageMaker Modellobjekt:

```
try:
 print("Deleting model...")
 sagemaker.delete_model(ModelName=MODEL_NAME)
 print(f"# Model '{MODEL_NAME}' deleted")
except Exception as e:
 print(f"# Error deleting model: {e}")
```

## Funktionen des Inferenzcontainers

Der Amazon SageMaker Nova-Inferenzcontainer enthält eine Reihe von Funktionen, die Sie aktivieren können, um das Modellverhalten während der Inferenz anzupassen. Jede Funktion wird in einer bestimmten Container-Version eingeführt und erfordert möglicherweise Umgebungsvariablen, Anforderungsparameter oder beides, um aktiviert zu werden.

Diese Seite listet die im Inferenzcontainer verfügbaren Funktionen auf, beschreibt, wie die einzelnen Funktionen aktiviert werden, und identifiziert die Containerversion, in der die Funktion eingeführt wurde. Anhand dieser Referenz können Sie ermitteln, welche Funktionen für Ihre Bereitstellung verfügbar sind und wie Sie sie konfigurieren.

Funktionen, die über Umgebungsvariablen aktiviert werden, werden bei der Erstellung der SageMaker Modell- oder Endpunktkonfiguration festgelegt. Nehmen Sie sie in den `Environment` Parameter des [CreateModel](#) API-Aufrufs auf. Funktionen, die durch Anforderungsparameter aktiviert werden, werden pro Aufruf im Anforderungstext festgelegt.

### Note

Verwenden Sie immer das neueste Container-Image, um Zugriff auf alle verfügbaren Funktionen zu erhalten. Das `SM-Inference-latest` Tag zeigt derzeit auf `v1.4`.

## Übersicht der Funktionen

Die folgende Tabelle bietet eine Kurzübersicht aller Funktionen, die im Amazon SageMaker Nova-Inferenzcontainer unterstützt werden.

### Zusammenfassung der Funktionen des Inferenz-Containers

| Feature                                                     | Wie aktiviert man        | Standard                              | Unterstützte Modelle     | Eingeführt in |
|-------------------------------------------------------------|--------------------------|---------------------------------------|--------------------------|---------------|
| <a href="#">Standardtemperatur</a>                          | Umgebungsvariable        | 1.0                                   | Alle Amazon Nova-Modelle | v1.0          |
| <a href="#">Standard-Top-p</a>                              | Umgebungsvariable        | 1.0                                   | Alle Amazon Nova-Modelle | v1.0          |
| <a href="#">Die Standardinstellung ist top-k</a>            | Umgebungsvariable        | -1 (deaktiviert)                      | Alle Amazon Nova-Modelle | v1.0          |
| <a href="#">Standardmäßige maximale Anzahl neuer Tokens</a> | Umgebungsvariable        | Die maximale Kontextlänge des Modells | Alle Amazon Nova-Modelle | v1.0          |
| <a href="#">Standard-Logprobs</a>                           | Umgebungsvariable        | Disabled                              | Alle Amazon Nova-Modelle | v1.0          |
| <a href="#">Spekulative Dekodierung mit Eagle3</a>          | Standardmäßig aktiviert. | Aktiviert                             | Alle Amazon Nova-Modelle | v1.0          |
| <a href="#">KV-Cache-Datentyp</a>                           | Umgebungsvariable        | Entspricht dem Modelldatentyp         | Alle Amazon Nova-Modelle | v1.3          |
| <a href="#">Quantisierung</a>                               | Umgebungsvariable        | Deaktiviert*                          | Alle Amazon Nova-Modelle | v1.3          |
| <a href="#">Anzahl der spekulativen Token</a>               | Umgebungsvariable        | 3                                     | Alle Amazon Nova-Modelle | v1.4          |

| Feature                                  | Wie aktiviert man | Standard | Unterstützte Modelle     | Eingeführt in |
|------------------------------------------|-------------------|----------|--------------------------|---------------|
| <a href="#">Dekodierung von Suffixen</a> | Umgebungsvariable | Disabled | Alle Amazon Nova-Modelle | v1.4          |

### Important

\* Die FP8-Quantisierung ist automatisch aktiviert und kann für die folgenden Kombinationen aus Modell und Instanztyp nicht deaktiviert werden:

- Amazon Nova Lite auf `m1.g6.12xlarge` oder `m1.g6.24xlarge`
- Nova 2 Lite an `m1.g6.48xlarge`

Für diese Konfigurationen müssen Sie keine Einstellungen vornehmen `QUANTIZATION_DTYPE`. Details dazu finden Sie unter [the section called "Quantisierung"](#).

## Standardtemperatur

Legt die Standard-Abtasttemperatur für alle Inferenzanfragen fest, die an den Endpunkt gesendet werden. Die Temperatur bestimmt, wie zufällig oder vorhersehbar die Ausgabe des Modells ist. Bei einem Wert von 0 wählt das Modell immer das wahrscheinlichste nächste Wort aus, wodurch eine konsistente und wiederholbare Ausgabe erzielt wird. Höhere Werte (bis zu 2) erhöhen die Bereitschaft des Modells, weniger wahrscheinliche Wörter auszuwählen, was zu kreativeren und vielfältigeren Antworten führt.

Verwendungszweck: Senken Sie die Temperatur (z. B. 0.1 auf 0.3) für Aufgaben, die sachliche, konsistente Antworten erfordern, wie Klassifizierung oder Datenextraktion. Erhöhen Sie den Wert (z. B. 0.7 auf 1.0) für kreative Aufgaben wie das Schreiben von Geschichten oder Brainstorming. Die Temperatur funktioniert zusammen mit Top-P und Top-K — alle drei steuern, wie das Modell Tokens auswählt, und Sie können sie kombinieren, um das Ausgabeverhalten zu optimieren.

Eingeführt in

v1.0

## Unterstützte Modelle

Alle Amazon Nova-Modelle

Wie aktiviert man

Legen Sie die `DEFAULT_TEMPERATURE` Umgebungsvariable fest, wenn Sie das SageMaker Modell erstellen.

Standardwert

1.0

Zulässige Werte

Schwebe zwischen 0 und 2 (einschließlich)

Umgebungsvariable

```
"Environment": {
 "DEFAULT_TEMPERATURE": "0.7"
}
```

### Note

Sie können diese Standardeinstellung für jede Anfrage außer Kraft setzen, indem Sie den `temperature` Parameter in den Hauptteil der Anfrage aufnehmen.

## Standard-Top-p

Legt den Standard-Top-p-Wert für alle Inferenzanfragen fest. Top-p steuert die Ausgabevielfalt, indem die Auswahlmöglichkeiten des Modells auf eine Teilmenge der wahrscheinlichsten Wörter beschränkt werden. Insbesondere sortiert das Modell alle möglichen nächsten Wörter nach Wahrscheinlichkeit und berücksichtigt nur die kleinste Gruppe, deren kombinierte Wahrscheinlichkeit den höchsten P-Wert erreicht. Ein Top-p 0.9 bedeutet beispielsweise, dass das Modell nur Wörter berücksichtigt, auf die zusammen 90% der Wahrscheinlichkeit entfallen, und die verbleibenden unwahrscheinlichen Optionen ignoriert.

Verwendungszweck: Verwenden Sie einen niedrigeren Top-p-Wert (z. B. 0.5), damit das Modell sich an Wörter mit hoher Zuverlässigkeit hält, was zu einer gezielteren Ausgabe führt. Verwenden

Sie einen höheren Wert (z. B. 0.95), um mehr Abwechslung zu ermöglichen. Top-p wird häufig als Alternative zur Temperatur verwendet — beide regeln die Ausgangsdiversität, aber Top-P passt sich dynamisch an, je nachdem, wie zuverlässig das Modell bei jedem Schritt ist. Sie können beide zusammen verwenden. In diesem Fall wendet das Modell bei jedem Schritt die Einschränkung an, die restriktiver ist.

Eingeführt in

v1.0

Unterstützte Modelle

Alle Amazon Nova-Modelle

Wie aktiviert man

Legen Sie die `DEFAULT_TOP_P` Umgebungsvariable fest, wenn Sie das SageMaker Modell erstellen.

Standardwert

1.0

Zulässige Werte

Schwebe zwischen  $1e-10$  und 1 (einschließlich)

Umgebungsvariable

```
"Environment": {
 "DEFAULT_TOP_P": "0.9"
}
```

#### Note

Sie können diese Standardeinstellung für jede Anfrage außer Kraft setzen, indem Sie den `top_p` Parameter in den Hauptteil der Anfrage aufnehmen.

Die Standardeinstellung ist top-k

Legt den standardmäßigen Top-K-Wert für alle Inferenzanfragen fest. Top-k beschränkt die Auswahlmöglichkeiten des Modells auf eine feste Anzahl der wahrscheinlichsten nächsten

Wörter. Ein Top-K 50 bedeutet beispielsweise, dass das Modell bei jedem Schritt nur die 50 wahrscheinlichsten Wörter berücksichtigt, unabhängig von ihren individuellen Wahrscheinlichkeiten. Ein Wert von -1 deaktiviert diesen Grenzwert, sodass das Modell alle möglichen Wörter berücksichtigen kann.

Verwendungszweck: Verwenden Sie Top-K, wenn Sie die Anzahl der vom Modell berücksichtigten Wortoptionen fest begrenzen möchten. Niedrigere Werte (zum Beispiel 10) führen zu einer besser vorhersehbaren Ausgabe, während höhere Werte mehr Abwechslung ermöglichen. Top-k kann mit Temperatur und Top-p kombiniert werden — wenn mehrere Probenahmekontrollen aktiv sind, wendet das Modell alle an, wobei bei jedem Schritt die restriktivste Methode verwendet wird.

Eingeführt in

v1.0

Unterstützte Modelle

Alle Amazon Nova-Modelle

Wie aktiviert man

Legen Sie die `DEFAULT_TOP_K` Umgebungsvariable fest, wenn Sie das SageMaker Modell erstellen.

Standardwert

-1(deaktiviert)

Zulässige Werte

Ganzzahl -1 oder größer. Wird verwendet -1, um alle Token zu berücksichtigen.

Umgebungsvariable

```
"Environment": {
 "DEFAULT_TOP_K": "50"
}
```

#### Note

Sie können diese Standardeinstellung für jede Anfrage außer Kraft setzen, indem Sie den `top_k` Parameter in den Hauptteil der Anfrage aufnehmen.



## Standardmäßige maximale Anzahl neuer Tokens

Legt die standardmäßige maximale Anzahl von Tokens (Wörtern oder Wortteilen) fest, die das Modell in einer Antwort generiert. Dieser Wert gilt für alle Anfragen, sofern er nicht überschrieben wird. Verwenden Sie diesen Wert, um die Antwortdauer zu kontrollieren und die Kosten auf Ihrem gesamten Endpunkt zu verwalten.

Verwendungszweck: Legen Sie diese Option fest, wenn Sie eine konsistente maximale Antwortdauer für alle Anfragen durchsetzen möchten. Stellen Sie es beispielsweise auf 256 für Aufgaben mit kurzen Antworten oder 2048 für die Generierung längerer Inhalte ein. Der zulässige Höchstwert hängt von dem für Ihren Endpunkt `CONTEXT_LENGTH` konfigurierten Wert ab, da Eingabe-Token und Ausgabetokens die Kontextlänge nicht überschreiten dürfen.

Eingeführt in

v1.0

Unterstützte Modelle

Alle Amazon Nova-Modelle

Wie aktiviert man

Legen Sie die `DEFAULT_MAX_NEW_TOKENS` Umgebungsvariable fest, wenn Sie das SageMaker Modell erstellen.

Standardwert

Die maximale Kontextlänge des Modells

Zulässige Werte

Ganzzahl 1 oder größer

Umgebungsvariable

```
"Environment": {
 "DEFAULT_MAX_NEW_TOKENS": "512"
}
```

 Note

Sie können diese Standardeinstellung für jede Anfrage außer Kraft setzen, indem Sie den `max_completion_tokens` Parameter `max_tokens` oder in den Anforderungstext aufnehmen. Der zulässige Höchstwert hängt von dem für Ihren Endpunkt `CONTEXT_LENGTH` konfigurierten Wert ab.

## Standard-Logprobs

Legt die Standardanzahl von Log-Wahrscheinlichkeiten fest, die für jedes generierte Token zurückgegeben werden sollen. Eine Log-Wahrscheinlichkeit ist ein numerischer Wert, der angibt, wie sicher das Modell bei der Auswahl der einzelnen Wörter war. Wenn diese Option aktiviert ist, umfasst die Antwort diese Werte für jedes Ausgabetoken. Dies ist nützlich, um die Zuverlässigkeit des Modells zu bewerten, alternative Wortwahlen zu vergleichen und das Generierungsverhalten zu debuggen.

Verwendungszweck: Aktivieren Sie Logprobs, wenn Sie beurteilen müssen, wie zuverlässig das Modell in seiner Ausgabe ist, z. B. um Antworten mit geringer Zuverlässigkeit zur Überprüfung durch einen Menschen zu kennzeichnen oder um die Wahrscheinlichkeit verschiedener Abschlüsse zu vergleichen. Die Aktivierung von Logprobs kann die Reaktionslatenz und die Größe der Antwortnutzlast geringfügig erhöhen.

Eingeführt in

v1.0

Unterstützte Modelle

Alle Amazon Nova-Modelle

Wie aktiviert man

Legen Sie die `DEFAULT_LOGPROBS` Umgebungsvariable fest, wenn Sie das SageMaker Modell erstellen.

Standardwert

Disabled

Zulässige Werte

Ganzzahl zwischen 1 und 20 (einschließlich)

## Umgebungsvariable

```
"Environment": {
 "DEFAULT_LOGPROBS": "5"
}
```

### Note

Sie können diese Standardeinstellung für jede Anfrage außer Kraft setzen, indem Sie die `top_logprobs` Parameter `logprobs` und in den Anforderungstext aufnehmen. Die Aktivierung von Logprobs kann die Antwortlatenz geringfügig erhöhen.

## Spekulative Dekodierung mit Eagle3

Die spekulative Eagle3-Dekodierung ist eine Optimierungstechnik, die die Textgenerierung beschleunigt. Es funktioniert, indem ein kleineres, schnelleres Entwurfsmodell verwendet wird, um mehrere Tokens im Voraus vorherzusagen, und diese Vorhersagen dann in einem einzigen Schritt mit dem Primärmodell verglichen. Wenn die Vorhersagen korrekt sind, generiert das Modell effektiv mehrere Token in der Zeit, die normalerweise für die Generierung eines Tokens erforderlich wäre. Das Primärmodell verifiziert immer die Entwurfs-Token, sodass das Endergebnis mit dem identisch ist, was das Primärmodell selbst produzieren würde — nur die Geschwindigkeit ändert sich, nicht die Qualität.

Verwendungszweck: Die spekulative Dekodierung von Eagle3 ist standardmäßig aktiviert und kommt den meisten Workloads zugute. Erwägen Sie, es nur zu deaktivieren, wenn Sie beim Debuggen ein unerwartetes Verhalten beobachten oder Leistungsmerkmale isolieren müssen.

### Eingeführt in

v1.0. Support für FP8-Quantisierung mit spekulativer Eagle3-Dekodierung wurde hinzugefügt.  
v1.4

### Unterstützte Modelle

Alle Amazon Nova-Modelle

### Wie aktiviert man

Die spekulative Dekodierung von Eagle3 ist standardmäßig aktiviert, ohne dass eine Konfiguration erforderlich ist. Verwenden Sie, um `DISABLE_SPECULATIVE_DECODING` es zu deaktivieren.

## Standardwert

`false`(Die spekulative Eagle3-Dekodierung ist aktiviert)

## Zulässige Werte

`true, false`

## Umgebungsvariable

Das folgende Beispiel deaktiviert die spekulative Eagle3-Dekodierung:

```
"Environment": {
 "DISABLE_SPECULATIVE_DECODING": "true"
}
```

## KV-Cache-Datentyp

Legt den Datentyp für den Schlüsselwert-Cache (KV) fest, der während der Inferenz verwendet wird. Der KV-Cache speichert den Speicher früherer Token des Modells in einer Konversation, sodass jedes neue Token generiert werden kann, ohne die gesamte Eingabe erneut verarbeiten zu müssen. Bei langen Sequenzen kann dieser Cache viel GPU-Speicher verbrauchen. Wenn Sie den KV-Cache auf einen Datentyp mit niedrigerer Genauigkeit wie FP8 einstellen, wird der Speicherverbrauch reduziert und der Durchsatz kann verbessert werden, allerdings auf Kosten geringfügiger numerischer Unterschiede bei der Ausgabe.

Verwendungszweck: Aktivieren Sie den FP8-KV-Cache, wenn Sie längere Kontextlängen oder eine höhere Parallelität auf Ihrer Instance unterstützen müssen. Dies ist besonders bei GPU-Instanzen mit begrenztem Arbeitsspeicher nützlich. Testen Sie Ihren Anwendungsfall, um sicherzustellen, dass die Ausgabequalität Ihren Anforderungen entspricht, da eine geringere Genauigkeit zu leicht unterschiedlichen Ergebnissen führen kann.

## Eingeführt in

`v1.3`

## Unterstützte Modelle

Alle Amazon Nova-Modelle

## Wie aktiviert man

Legen Sie die `KV_CACHE_DTYPE` Umgebungsvariable fest, wenn Sie das SageMaker Modell erstellen.

## Standardwert

Entspricht dem Datentyp des Modells

## Zulässige Werte

fp8

## Umgebungsvariable

```
"Environment": {
 "KV_CACHE_DTYPE": "fp8"
}
```

### Note

Eine Änderung des KV-Cache-Datentyps kann zu geringfügig anderen Ausgaben als bei der Standardgenauigkeit führen. Testen Sie Ihren Anwendungsfall, um sicherzustellen, dass die Ausgabequalität Ihren Anforderungen entspricht.

## Quantisierung

Legt den Quantisierungsdattentyp für Modellgewichte fest. Bei der Quantisierung werden die Gewichtungen des Modells in ein Format mit niedrigerer Genauigkeit komprimiert (FP8 statt der standardmäßigen höheren Genauigkeit), wodurch der für das Modell benötigte GPU-Speicher reduziert wird. Dies kann den Inferenzdurchsatz verbessern und es größeren Modellen ermöglichen, auf kleinere Instance-Typen zu passen, ohne dass die Ausgabequalität beeinträchtigt wird.

Verwendungszweck: Verwenden Sie die FP8-Quantisierung, wenn Sie die Speicherauslastung reduzieren möchten, um eine höhere Parallelität zu unterstützen, oder wenn Sie ein Modell an einen kleineren Instance-Typ anpassen möchten. Beachten Sie, dass bei einigen Kombinationen aus Modell und Instanztyp die automatische FP8-Quantisierung erforderlich ist — siehe die Warnung unten.

## Eingeführt in

v1.3

## Unterstützte Modelle

Alle Amazon Nova-Modelle

## Wie aktiviert man

Legen Sie die `QUANTIZATION_DTYPE` Umgebungsvariable fest, wenn Sie das SageMaker Modell erstellen.

## Standardwert

Deaktiviert. Die FP8-Quantisierung wird jedoch für bestimmte Kombinationen aus Modell und Instanztyp automatisch aktiviert. Siehe den Hinweis unten.

## Zulässige Werte

fp8

## Umgebungsvariable

```
"Environment": {
 "QUANTIZATION_DTYPE": "fp8"
}
```

### Important

Die folgenden Kombinationen aus Modell und Instanztyp erfordern eine FP8-Quantisierung. Für diese Konfigurationen wird die Quantisierung automatisch aktiviert und kann nicht deaktiviert oder außer Kraft gesetzt werden:

- Amazon Nova Lite auf `m1.g6.12xlarge` oder `m1.g6.24xlarge`
- Nova 2 Lite an `m1.g6.48xlarge`

Einzelheiten zu allen anderen Konfigurationen finden [the section called “Unterstützte Modelle und Instanzen”](#) Sie unter.

## Anzahl der spekulativen Token

Steuert, wie viele Token der Modellentwurf bei jedem spekulativen Dekodierungsschritt von Eagle3 voraussagt. Ein höherer Wert bedeutet, dass der Modellentwurf versucht, mehr Tokens gleichzeitig vorherzusagen, wodurch der Durchsatz verbessert werden kann, wenn die Prognosen korrekt sind. Wenn die Vorhersagen des Modellentwurfs häufig vom Primärmodell abweichen, kann ein niedrigerer Wert effizienter sein.

Verwendungszweck: Erhöhen Sie diesen Wert, wenn Ihr Workload vorhersehbare Ausgabemuster erzeugt (z. B. strukturierte Daten oder Vorlagentext), bei denen das Entwurfsmodell wahrscheinlich richtig raten wird. Verringern Sie ihn für kreative oder stark variable Ergebnisse, bei denen Vorhersagen weniger zuverlässig sind.

Eingeführt in

v1.4

Unterstützte Modelle

Alle Amazon Nova-Modelle

Wie aktiviert man

Legen Sie die `NUM_SPECULATIVE_TOKENS` Umgebungsvariable fest, wenn Sie das SageMaker Modell erstellen.

Standardwert

3

Zulässige Werte

Ganzzahl zwischen 1 und 10 (einschließlich)

Umgebungsvariable

```
"Environment": {
 "NUM_SPECULATIVE_TOKENS": "5"
}
```

 Note

Diese Einstellung gilt nur, wenn die spekulative Eagle3-Dekodierung aktiviert ist (ist). `DISABLE_SPECULATIVE_DECODING false` hat keine Auswirkung, wenn die spekulative Dekodierung deaktiviert ist oder wenn die Suffixdekodierung verwendet wird.

## Dekodierung von Suffixen

Die Suffixdekodierung ist eine alternative Methode zur Beschleunigung der Textgenerierung. Anstatt ein separates Entwurfsmodell zu verwenden (wie es Eagle3 tut), sucht die Suffixdekodierung nach wiederholten Mustern im bereits generierten Text oder in der Eingabeaufforderung und verwendet diese Muster wieder, um future Token vorherzusagen. Dieser Ansatz funktioniert gut, wenn die Ausgabe wahrscheinlich wiederholte Phrasen, strukturierte Formate oder Inhalte enthält, die der Eingabe sehr ähnlich sind.

Verwendungszweck: Verwenden Sie die Suffixdekodierung für Aufgaben, bei denen die Ausgabe sich wiederholende Muster enthält, z. B. das Generieren strukturierter Daten, das Ausfüllen von Vorlagen oder das Zusammenfassen von Inhalten, bei denen Phrasen aus der Quelle wiederverwendet werden. Bei der Generierung für allgemeine Zwecke, bei denen die Ausgabe sehr unterschiedlich ist, bietet die Standardmethode Eagle3 in der Regel einen besseren Durchsatz.

### Eingeführt in

v1.4

### Unterstützte Modelle

Alle Amazon Nova-Modelle

### Wie aktiviert man

Stellen Sie die `SPECULATIVE_DECODING_METHOD` Umgebungsvariable auf ein, `suffix` wenn Sie das SageMaker Modell erstellen.

### Standardwert

`eagle3`

### Zulässige Werte

`eagle3, suffix`



## Umgebungsvariable

```
"Environment": {
 "SPECULATIVE_DECODING_METHOD": "suffix"
}
```

### Note

Um die Suffix-Dekodierung zu verwenden, `DISABLE_SPECULATIVE_DECODING` muss sie auf `false` (Standard) gesetzt sein. Die Einstellung `DISABLE_SPECULATIVE_DECODING` auf `true` deaktiviert alle spekulativen Dekodierungsmethoden, einschließlich der Suffixdekodierung.

## API-Referenz

Amazon Nova-Modelle SageMaker verwenden die SageMaker Standard-Runtime-API für Inferenz. Eine vollständige API-Dokumentation finden Sie unter [Testen eines bereitgestellten Modells](#).

### Aufruf von Endpunkten

Amazon Nova-Modelle auf SageMaker unterstützen zwei Aufrufmethoden:

- Synchroner Aufruf: Verwenden Sie die [InvokeEndpoint](#) API für Inferenzanfragen in Echtzeit, die kein Streaming erfordern.
- Streaming-Aufruf: Verwenden Sie die [InvokeEndpointWithResponseStream](#) API für Streaming-Inferenzanfragen in Echtzeit.

### Anforderungsformat

Amazon Nova-Modelle unterstützen zwei Anforderungsformate:

Format für den Abschluss des Chats

Verwenden Sie dieses Format für Konversationsinteraktionen:

```
{
 "messages": [
 {"role": "user", "content": "string"}
]
}
```

```
],
"max_tokens": integer,
"max_completion_tokens": integer,
"stream": boolean,
"temperature": float,
"top_p": float,
"top_k": integer,
"logprobs": boolean,
"top_logprobs": integer,
"reasoning_effort": "low" | "high",
"allowed_token_ids": [integer],
"truncate_prompt_tokens": integer,
"stream_options": {
 "include_usage": boolean
}
}
```

### Format für die Textvervollständigung

Verwenden Sie dieses Format für die einfache Textgenerierung:

```
{
 "prompt": "string",
 "max_tokens": integer,
 "stream": boolean,
 "temperature": float,
 "top_p": float,
 "top_k": integer,
 "logprobs": integer,
 "allowed_token_ids": [integer],
 "truncate_prompt_tokens": integer,
 "stream_options": {
 "include_usage": boolean
 }
}
```

### Format für die Fertigstellung eines multimodalen Chats

Verwenden Sie dieses Format für Bild- und Texteingaben:

```
{
 "messages": [
 {
```

```

 "role": "user",
 "content": [
 {"type": "text", "text": "What's in this image?"},
 {"type": "image_url", "image_url": {"url": "data:image/jpeg;base64,..."}}
]
 },
 "max_tokens": integer,
 "temperature": float,
 "top_p": float,
 "stream": boolean
}

```

## Anfrageparameter

- **messages(Array):** Für das Format zum Abschluss eines Chats. Array von Nachrichtenobjekten mit content Feldern role und. Inhalt kann eine Zeichenfolge für reine Texteingaben oder ein Array für multimodale Eingaben sein.
- **prompt(Zeichenfolge):** Für das Textvervollständigungsformat. Der Eingabetext, aus dem generiert werden soll.
- **max\_tokens(Ganzzahl):** Maximale Anzahl von Token, die in der Antwort generiert werden sollen. Bereich: 1 oder größer.
- **max\_completion\_tokens(Ganzzahl):** Alternative zu max\_tokens für Chat-Abschlüsse. Maximale Anzahl der zu generierenden Abschluss-Token.
- **temperature(float):** Steuert die Zufälligkeit bei der Generierung. Bereich: 0,0 bis 2,0 (0,0 = deterministisch, 2,0 = maximale Zufälligkeit).
- **top\_p(Float):** Schwellenwert für die Nukleus-Probenahme. Bereich: 1e-10 bis 1,0.
- **top\_k(Ganzzahl):** Beschränkt die Token-Auswahl auf die Top K der wahrscheinlichsten Tokens. Bereich: -1 oder größer (-1 = kein Limit).
- **stream(boolean):** Ob die Antwort gestreamt werden soll. Auf für Streaming, true für Nicht-Streaming eingestellt. false
- **logprobs(boolesch/Ganzzahl):** Verwenden Sie für Chat-Abschlüsse den booleschen Wert. Verwenden Sie für Textvervollständigungen eine Ganzzahl für die Anzahl der zurückzugebenden Log-Wahrscheinlichkeiten. Bereich: 1 bis 20.
- **top\_logprobs(Ganzzahl):** Anzahl der Token, für die die Wahrscheinlichkeit am wahrscheinlichsten ist, dass Log-Wahrscheinlichkeiten zurückgegeben werden (nur Chat-Abschlüsse).

- `reasoning_effort`(Zeichenfolge): Umfang des Argumentationsaufwands. Optionen: „niedrig“, „hoch“ (Chat-Abschlüsse nur für benutzerdefinierte Nova 2 Lite-Modelle).
- `allowed_token_ids`(Array): Liste der Token IDs , die generiert werden dürfen. Beschränkt die Ausgabe auf bestimmte Token.
- `truncate_prompt_tokens`(Ganzzahl): Kürzt die Eingabeaufforderung auf diese Anzahl von Token, wenn sie das Limit überschreitet.
- `stream_options`(Objekt): Optionen für das Streamen von Antworten. Enthält einen `include_usage` booleschen Wert, um die Token-Verwendung in Streaming-Antworten einzubeziehen.

## Reaktionsformat

Das Antwortformat hängt von der Aufrufmethode und dem Anforderungstyp ab:

Antwort auf den Abschluss des Chats (kein Streaming)

Für Anfragen zum synchronen Abschluss eines Chats:

```
{
 "id": "chatcmpl-123e4567-e89b-12d3-a456-426614174000",
 "object": "chat.completion",
 "created": 1677652288,
 "model": "nova-micro-custom",
 "choices": [
 {
 "index": 0,
 "message": {
 "role": "assistant",
 "content": "Hello! I'm doing well, thank you for asking. How can I help you today?",
 "refusal": null,
 "reasoning": null,
 "reasoning_content": null
 },
 "logprobs": {
 "content": [
 {
 "token": "Hello",
 "logprob": -0.31725305,
 "bytes": [72, 101, 108, 108, 111],
 "top_logprobs": [
```

```

 {
 "token": "Hello",
 "logprob": -0.31725305,
 "bytes": [72, 101, 108, 108, 111]
 },
 {
 "token": "Hi",
 "logprob": -1.3190403,
 "bytes": [72, 105]
 }
]
],
 "finish_reason": "stop",
 "stop_reason": null,
 "token_ids": [9906, 0, 358, 2157, 1049, 11, 1309, 345, 369, 6464, 13]
 }
],
"usage": {
 "prompt_tokens": 9,
 "completion_tokens": 12,
 "total_tokens": 21,
 "prompt_tokens_details": {
 "cached_tokens": 0
 }
},
"prompt_token_ids": [9906, 0, 358]
}

```

Antwort auf die Textvervollständigung (kein Streaming)

Für Anfragen zur synchronen Textvervollständigung:

```

{
 "id": "cmpl-123e4567-e89b-12d3-a456-426614174000",
 "object": "text_completion",
 "created": 1677652288,
 "model": "nova-micro-custom",
 "choices": [
 {
 "index": 0,
 "text": "Paris, the capital and most populous city of France.",
 "logprobs": {

```

```

 "tokens": ["Paris", ",", " the", " capital"],
 "token_logprobs": [-0.31725305, -0.07918124, -0.12345678, -0.23456789],
 "top_logprobs": [
 {
 "Paris": -0.31725305,
 "London": -1.3190403,
 "Rome": -2.1234567
 },
 {
 ",": -0.07918124,
 " is": -1.2345678
 }
],
 "finish_reason": "stop",
 "stop_reason": null,
 "prompt_token_ids": [464, 6864, 315, 4881, 374],
 "token_ids": [3915, 11, 279, 6864, 323, 1455, 95551, 3363, 315, 4881, 13]
 }
],
"usage": {
 "prompt_tokens": 5,
 "completion_tokens": 11,
 "total_tokens": 16,
 "prompt_tokens_details": {
 "cached_tokens": 0
 }
}
}

```

## Streaming-Antwort auf Abschluss des Chats

Bei Anfragen zur Beendigung des Streaming-Chats werden Antworten als vom Server gesendete Ereignisse (SSE) gesendet:

```

data: {
 "id": "chatcmpl-123e4567-e89b-12d3-a456-426614174000",
 "object": "chat.completion.chunk",
 "created": 1677652288,
 "model": "nova-micro-custom",
 "choices": [
 {
 "index": 0,

```

```
 "delta": {
 "role": "assistant",
 "content": "Hello",
 "refusal": null,
 "reasoning": null,
 "reasoning_content": null
 },
 "logprobs": {
 "content": [
 {
 "token": "Hello",
 "logprob": -0.31725305,
 "bytes": [72, 101, 108, 108, 111],
 "top_logprobs": [
 {
 "token": "Hello",
 "logprob": -0.31725305,
 "bytes": [72, 101, 108, 108, 111]
 }
]
 }
]
 },
 "finish_reason": null,
 "stop_reason": null
 }
],
"usage": null,
"prompt_token_ids": null
}

data: {
 "id": "chatcmpl-123e4567-e89b-12d3-a456-426614174000",
 "object": "chat.completion.chunk",
 "created": 1677652288,
 "model": "nova-micro-custom",
 "choices": [
 {
 "index": 0,
 "delta": {
 "content": "! I'm"
 },
 "logprobs": null,
 "finish_reason": null,
 }
]
}
```

```
 "stop_reason": null
 }
],
"usage": null
}

data: {
 "id": "chatcmpl-123e4567-e89b-12d3-a456-426614174000",
 "object": "chat.completion.chunk",
 "created": 1677652288,
 "model": "nova-micro-custom",
 "choices": [
 {
 "index": 0,
 "delta": {},
 "finish_reason": "stop",
 "stop_reason": null
 }
],
 "usage": {
 "prompt_tokens": 9,
 "completion_tokens": 12,
 "total_tokens": 21,
 "prompt_tokens_details": {
 "cached_tokens": 0
 }
 }
}

data: [DONE]
```

## Streaming-Antwort zur Textvervollständigung

Für Streaming-Anfragen zur Textvervollständigung:

```
data: {
 "id": "cmpl-123e4567-e89b-12d3-a456-426614174000",
 "object": "text_completion",
 "created": 1677652288,
 "model": "nova-micro-custom",
 "choices": [
 {
 "index": 0,
 "text": "Paris",
```



```
 "logprobs": {
 "tokens": ["Paris"],
 "token_logprobs": [-0.31725305],
 "top_logprobs": [
 {
 "Paris": -0.31725305,
 "London": -1.3190403
 }
]
 },
 "finish_reason": null,
 "stop_reason": null
 }
],
"usage": null
}

data: {
 "id": "cmpl-123e4567-e89b-12d3-a456-426614174000",
 "object": "text_completion",
 "created": 1677652288,
 "model": "nova-micro-custom",
 "choices": [
 {
 "index": 0,
 "text": ", the capital",
 "logprobs": null,
 "finish_reason": null,
 "stop_reason": null
 }
],
 "usage": null
}

data: {
 "id": "cmpl-123e4567-e89b-12d3-a456-426614174000",
 "object": "text_completion",
 "created": 1677652288,
 "model": "nova-micro-custom",
 "choices": [
 {
 "index": 0,
 "text": "",
 "finish_reason": "stop",
```

```
 "stop_reason": null
 }
],
"usage": {
 "prompt_tokens": 5,
 "completion_tokens": 11,
 "total_tokens": 16
}
}

data: [DONE]
```

## Erklärung der Antwortfelder

- **id**: Eindeutiger Bezeichner für den Abschluss
- **object**: Typ des zurückgegebenen Objekts („chat.completion“, „text\_completion“, „chat.completion.chunk“)
- **created**: Unix-Zeitstempel, wann die Vervollständigung erstellt wurde
- **model**: Für die Fertigstellung verwendetes Modell
- **choices**: Eine Reihe von Optionen für die Fertigstellung
- **usage**: Informationen zur Token-Nutzung, einschließlich Eingabeaufforderung, Fertigstellung und Gesamtzahl der Tokens
- **logprobs**: Informationen zur Wahrscheinlichkeit von Tokens protokollieren (falls angefordert)
- **finish\_reason**: Grund, warum das Modell die Generierung eingestellt hat („stop“, „length“, „content\_filter“)
- **delta**: Inkrementeller Inhalt in Streaming-Antworten
- **reasoning**: Inhalt zur Argumentation, wenn **reasoning\_effort** verwendet wird
- **token\_ids**: Token-Array für den generierten Text IDs

Eine vollständige API-Dokumentation finden Sie unter [InvokeEndpoint API-Referenz](#) und [InvokeEndpointWithResponseStream API-Referenz](#).

# Einsatz von Amazon Nova Forge-Modellen bei der Missbrauchserkennung von Amazon SageMaker Inference

AWS setzt sich für den verantwortungsvollen Umgang mit KI ein. Um potenziellen Missbrauch zu verhindern, implementiert Inference bei der Bereitstellung von Amazon Nova Forge-Modellen in Amazon SageMaker Inference automatisierte Mechanismen zur Missbrauchserkennung, SageMaker um potenzielle Verstöße gegen die [Acceptable Use Policy](#) (AUP) und die Servicebedingungen, einschließlich der [Responsible](#) AI Policy, zu identifizieren. AWS

Unsere Mechanismen zur Missbrauchserkennung sind vollständig automatisiert, sodass es keine menschliche Überprüfung von oder menschlichen Zugriff auf Benutzereingaben oder Modellausgaben gibt.

Die automatische Missbrauchserkennung umfasst:

- **Inhalte kategorisieren** — Wir verwenden Klassifikatoren, um schädliche Inhalte (z. B. Inhalte, die zu Gewalt aufrufen) in Benutzereingaben und Modellausgaben zu erkennen. Ein Klassifizierer ist ein Algorithmus, der Modellein- und -ausgaben verarbeitet und die Art des Schadens und das Maß der Zuverlässigkeit zuweist. Wir können diese Klassifikatoren bei Verwendung des Amazon Nova Forge-Modells ausführen. Der Klassifizierungsprozess ist automatisiert und umfasst keine menschliche Überprüfung von Benutzereingaben oder Modellausgaben.
- **Identifizieren Sie Muster** — Wir verwenden Klassifikator-Metriken, um potenzielle Verstöße und wiederkehrendes Verhalten zu identifizieren. Wir können anonymisierte Klassifikator-Metriken zusammenstellen und weitergeben. Amazon SageMaker Inference speichert keine Benutzereingaben oder Modellausgaben.
- **Erkennen und Blockieren von Material über sexuellen Missbrauch von Kindern (CSAM)** — Sie sind für die Inhalte verantwortlich, die Sie (und Ihre Endbenutzer) auf Amazon SageMaker Inference hochladen, und müssen sicherstellen, dass diese Inhalte frei von illegalen Bildern sind. Um die Verbreitung von CSAM zu verhindern, kann Inference bei der Bereitstellung eines Amazon Nova Forge-Modells in Amazon SageMaker Inference automatisierte Mechanismen zur Missbrauchserkennung (wie Hash-Matching-Technologie oder Klassifikatoren) einsetzen, um offensichtliche CSAMs zu erkennen. SageMaker Wenn Amazon SageMaker Inference offensichtliches CSAM in Ihren Bildeingaben erkennt, blockiert Amazon SageMaker Inference die Anfrage und Sie erhalten eine automatische Fehlermeldung. Amazon SageMaker Inference kann auch einen Bericht beim National Center for Missing and Exploited Children (NCMEC) oder einer zuständigen Behörde einreichen. Wir nehmen CSAM sehr ernst und werden unsere Erkennungs-, Blockier- und Meldemechanismen weiterhin aktualisieren. Möglicherweise sind Sie nach geltendem

Recht verpflichtet, zusätzliche Maßnahmen zu ergreifen, und Sie sind für diese Maßnahmen verantwortlich.

Sobald unsere automatisierten Mechanismen zur Missbrauchserkennung potenzielle Verstöße erkennen, können wir Informationen über Ihre Nutzung von Amazon SageMaker Inference und die Einhaltung unserer Nutzungsbedingungen anfordern. Falls Sie nicht antworten, nicht bereit oder nicht in der Lage sind, diese Bedingungen oder Richtlinien einzuhalten, AWS können Sie Ihren Zugriff auf Amazon SageMaker Inference sperren. Möglicherweise wird Ihnen auch der fehlgeschlagene Inferenzauftrag in Rechnung gestellt, wenn unsere automatisierten Tests feststellen, dass Modellantworten nicht mit unseren Bedingungen und Richtlinien vereinbar sind.

Falls Sie weitere Fragen haben, wenden Sie sich an den AWS Support. Weitere Informationen finden Sie auf [Amazon SageMaker FAQs](#).

## Amazon-Bedrock-Inferenz

Sobald Sie Ihr Amazon Nova-Modell trainiert und getestet haben, können Sie es auf Amazon Bedrock bereitstellen, um Inferenzen im Produktionsmaßstab zu erhalten. Der Bereitstellungsprozess umfasst die Erstellung eines Amazon Bedrock-Modells mit der CreateCustomModel API, den Export Ihrer Modellartefakte aus einem verwalteten Amazon S3 S3-Bucket in dieses Modell und die Konfiguration eines Endpunkts mit On-Demand-Inferenz oder bereitgestelltem Durchsatz, sobald das Modell AKTIV ist.

Nachdem Sie ein benutzerdefiniertes Modell erstellt haben SageMaker, können Sie es mithilfe der CreateCustomModel API vom SageMaker Treuhandkonto auf Amazon Bedrock bereitstellen, um Inferenz auszuführen. Sie können es dann verwenden CreateCustomModelDeployment , um einen OD-Inferenzendpunkt zu erstellen oder eine bereitgestellte Durchsatzinferenz für ein PEFT-Modell (Parameter Efficient Fine Tuned) einzurichten. Sie können die bereitgestellte Durchsatzinferenz für ein benutzerdefiniertes Full-Rank-Modell einrichten.

Sie können auch das Amazon Nova Forge SDK verwenden, um maßgeschneiderte Amazon Nova-Modelle bereitzustellen. Das Amazon Nova Forge SDK bietet eine optimierte Erfahrung beim Extrahieren der relevanten Informationen aus einem Schulungsjob oder einem S3-Modell-Checkpoint und deren Veröffentlichung in Amazon Bedrock. Weitere Informationen finden Sie unter [Amazon Nova Forge SDK](#).

Ausführliche Schritte zur Einrichtung der Amazon Bedrock-Inferenz für ein benutzerdefiniertes Modell finden Sie unter [Bereitstellen von benutzerdefinierten Amazon Nova-Modellen in Amazon Bedrock](#).

Der folgende Abschnitt enthält weitere Informationen zu On-Demand Inference on Custom Models.

## Ein benutzerdefiniertes Modell für On-Demand-Inferenz bereitstellen

Nachdem Sie erfolgreich ein benutzerdefiniertes Modell mit einem Modellanpassungsauftrag (Feinabstimmung, Destillation oder fortgesetztes Vortraining) erstellt haben, können Sie eine On-Demand-Inferenz für das Modell einrichten.

Um On-Demand-Inferenz für ein benutzerdefiniertes Modell einzurichten, stellen Sie das Modell mit einer benutzerdefinierten Modellbereitstellung bereit. Nachdem Sie Ihr benutzerdefiniertes Modell bereitgestellt haben, verwenden Sie den Amazon-Ressourcennamen (ARN) der Bereitstellung als `modelId`-Parameter in Ihren `InvokeModel`- oder `Converse`-API-Vorgängen. Sie können das bereitgestellte Modell für On-Demand-Inferenzen mit Amazon-Bedrock-Features wie Playgrounds, Agents und Wissensdatenbanken verwenden.

### Themen

- [Unterstützte Modelle](#)
- [Bereitstellen eines benutzerdefinierten Modells](#)
- [Verwenden einer Bereitstellung für die On-Demand-Inferenz](#)
- [Eine benutzerdefinierte Modellbereitstellung löschen](#)

## Unterstützte Modelle

Sie können On-Demand-Inferenz für die folgenden Modelle einrichten:

- Amazon Nova Canvas
- Amazon Nova Lite
- Amazon Nova Micro
- Amazon Nova Pro

## Bereitstellen eines benutzerdefinierten Modells

Sie können ein benutzerdefiniertes Modell mit der Amazon Bedrock-Konsole, AWS Command Line Interface, oder AWS SDKs bereitstellen. Informationen zur Verwendung der Bereitstellung für die Inferenz finden Sie unter [Verwenden einer Bereitstellung für die On-Demand-Inferenz](#).

## Themen

- [Bereitstellen eines benutzerdefinierten Modells \(Konsole\)](#)
- [Bereitstellen eines benutzerdefinierten Modells \(AWS Command Line Interface\)](#)
- [Bereitstellen eines benutzerdefinierten Modells \(AWS SDKs\)](#)

### Bereitstellen eines benutzerdefinierten Modells (Konsole)

Sie stellen ein benutzerdefiniertes Modell auf der Seite Benutzerdefinierte Modelle wie folgt bereit. Sie können ein Modell auch über die Seite Benutzerdefiniertes On-Demand-Modell mit denselben Feldern bereitstellen. Sie finden diese Seite, indem Sie im Navigationsbereich unter Inferenz und Bewertung die Option Benutzerdefiniertes On-Demand-Modell auswählen.

So stellen Sie ein benutzerdefiniertes Modell bereit

1. Melden Sie sich bei der [Rolle AWS-Managementkonsole Using an IAM mit Amazon Bedrock-Berechtigungen](#) an und öffnen Sie die Amazon Bedrock-Konsole unter <https://console.aws.amazon.com/nova/>
2. Wählen Sie im linken Navigationsbereich unter Grundlagenmodelle die Option Benutzerdefinierte Modelle aus.
3. Wählen Sie auf der Registerkarte Modelle das Optionsfeld für das Modell aus, das Sie bereitstellen möchten.
4. Wählen Sie Inferenz einrichten und anschließend Auf Abruf bereitstellen aus.
5. Geben Sie unter Einzelheiten zur Bereitstellung die folgenden Informationen an:
  - Name der Bereitstellung (erforderlich) – Geben Sie einen eindeutigen Namen für die Bereitstellung ein.
  - Beschreibung (optional) – Geben Sie eine Beschreibung der Bereitstellung ein.
  - Tags (optional) – Fügen Sie Tags für die Kostenzuordnung und das Ressourcenmanagement hinzu.
6. Wählen Sie Erstellen aus. Wenn der Status der Bereitstellung Completed lautet, ist das benutzerdefinierte Modell bereit für On-Demand-Inferenz. Weitere Informationen zur Verwendung des benutzerdefinierten Modells finden Sie unter [Verwenden einer Bereitstellung für die On-Demand-Inferenz](#).

## Bereitstellen eines benutzerdefinierten Modells (AWS Command Line Interface)

Um ein benutzerdefiniertes Modell für On-Demand-Inferenzen mithilfe von bereitgestellten AWS Command Line Interface, verwenden Sie den `create-custom-model-deployment` Befehl mit dem Amazon-Ressourcennamen (ARN) Ihres benutzerdefinierten Modells. Dieser Befehl verwendet die [CreateCustomModelDeployment](#) API-Operation. Gibt den ARN der Bereitstellung zurück, den Sie als `modelId` bei Inferenzanfragen verwenden können. Informationen zur Verwendung der Bereitstellung für die Inferenz finden Sie unter [Verwenden einer Bereitstellung für die On-Demand-Inferenz](#).

```
aws bedrock create-custom-model-deployment \
--model-deployment-name "Unique name" \
--model-arn "Custom Model ARN" \
--description "Deployment description" \
--tags '[
 {
 "key": "Environment",
 "value": "Production"
 },
 {
 "key": "Team",
 "value": "ML-Engineering"
 },
 {
 "key": "Project",
 "value": "CustomerSupport"
 }
]' \
--client-request-token "unique-deployment-token" \
--region region
```

## Bereitstellen eines benutzerdefinierten Modells (AWS SDKs)

Um ein benutzerdefiniertes Modell für On-Demand-Inferenzen bereitzustellen, verwenden Sie den [CreateCustomModelDeployment](#) API-Vorgang mit dem Amazon-Ressourcennamen (ARN) Ihres benutzerdefinierten Modells. Die Antwort gibt den ARN der Bereitstellung zurück, den Sie als `modelId` bei Inferenzanfragen verwenden können. Informationen zur Verwendung der Bereitstellung für die Inferenz finden Sie unter [Verwenden einer Bereitstellung für die On-Demand-Inferenz](#).

Der folgende Code zeigt, wie Sie das SDK für Python (Boto3) verwenden, um ein benutzerdefiniertes Modell bereitzustellen.

```
def create_custom_model_deployment(bedrock_client):
 """Create a custom model deployment
 Args:
 bedrock_client: A boto3 Bedrock client for making API calls

 Returns:
 str: The ARN of the created custom model deployment

 Raises:
 Exception: If there is an error creating the deployment
 """

 try:
 response = bedrock_client.create_custom_model_deployment(
 modelDeploymentName="Unique deployment name",
 modelArn="Custom Model ARN",
 description="Deployment description",
 tags=[
 {'key': 'Environment', 'value': 'Production'},
 {'key': 'Team', 'value': 'ML-Engineering'},
 {'key': 'Project', 'value': 'CustomerSupport'}
],
 clientRequestToken=f"deployment-{uuid.uuid4()}"
)

 deployment_arn = response['customModelDeploymentArn']
 print(f"Deployment created: {deployment_arn}")
 return deployment_arn

 except Exception as e:
 print(f"Error creating deployment: {str(e)}")
 raise
```

## Verwenden einer Bereitstellung für die On-Demand-Inferenz

Nachdem Sie Ihr benutzerdefiniertes Modell für On-Demand-Inferenz bereitgestellt haben, können Sie es verwenden, um Antworten zu generieren, indem Sie Inferenzanfragen stellen. Für InvokeModel- oder Converse-Vorgänge verwenden Sie den Amazon-Ressourcennamen (ARN) der Bereitstellung als modelId.

Informationen zum Anfordern von Inferenzen finden Sie in den folgenden Themen:



- [Prompts senden und Antworten mit Modellinferenz generieren](#)
- [Voraussetzungen für die Ausführung der Modellinferenz](#)
- [Mithilfe der API Prompts einreichen und Antworten generieren](#)

## Eine benutzerdefinierte Modellbereitstellung löschen

Wenn Sie Ihr Modell nicht mehr für On-Demand-Inferenz verwenden, können Sie die Bereitstellung löschen. Nachdem Sie die Bereitstellung gelöscht haben, können Sie sie nicht für On-Demand-Inferenz verwenden, dadurch wird das zugrunde liegende benutzerdefinierte Modell jedoch nicht gelöscht.

Sie können eine benutzerdefinierte Modellbereitstellung mit der Amazon Bedrock-Konsole, AWS Command Line Interface, oder AWS SDKs löschen.

### Important

Das Löschen einer Bereitstellung eines benutzerdefinierten Modells kann nicht rückgängig gemacht werden. Stellen Sie sicher, dass Sie die Bereitstellung nicht mehr benötigen, bevor Sie mit dem Löschen fortfahren. Wenn Sie das benutzerdefinierte Modell erneut für On-Demand-Inferenz verwenden müssen, müssen Sie eine neue Bereitstellung erstellen.

## Themen

- [Löschen einer benutzerdefinierten Modellbereitstellung \(Konsole\)](#)
- [Eine benutzerdefinierte Modellbereitstellung löschen \(AWS Command Line Interface\)](#)
- [Löschen einer benutzerdefinierten Modellbereitstellung \(AWS SDKs\)](#)

## Löschen einer benutzerdefinierten Modellbereitstellung (Konsole)

So löschen Sie eine benutzerdefinierte Modellbereitstellung

1. Wählen Sie im Navigationsbereich unter Inferenz und Bewertung die Option Benutzerdefiniertes On-Demand-Modell aus.
2. Wählen Sie die benutzerdefinierte Modellbereitstellung aus, die Sie löschen möchten.
3. Wählen Sie Löschen aus.

4. Geben Sie in das Bestätigungsfeld den Bereitstellungsnamen ein, um das Löschen zu bestätigen.
5. Wählen Sie zur Bestätigung Delete.

Der Bereitstellungsstatus ändert sich während des Löschvorgangs zu `Deleting`. Nach Abschluss wird die Bereitstellung aus der Liste entfernt.

### Eine benutzerdefinierte Modellbereitstellung löschen (AWS Command Line Interface)

Um eine benutzerdefinierte Modellbereitstellung mithilfe von zu löschen AWS Command Line Interface, verwenden Sie den `delete-custom-model-deployment` Befehl mit Ihrer Bereitstellungs-ID.

```
aws bedrock delete-custom-model-deployment \
--custom-model-deployment-identifier "deployment-arn-or-name" \
--region region
```

### Löschen einer benutzerdefinierten Modellbereitstellung (AWS SDKs)

Um eine benutzerdefinierte Modellbereitstellung programmgesteuert zu löschen, verwenden Sie den [DeleteCustomModelDeployment](#) API-Vorgang mit dem Amazon-Ressourcennamen (ARN) oder Namen der Bereitstellung. Der folgende Code zeigt, wie Sie das SDK for Python (Boto3) einsetzen, um eine benutzerdefinierte Modellbereitstellung zu löschen.

```
def delete_custom_model_deployment(bedrock_client):
 """Delete a custom model deployment

 Args:
 bedrock_client: A boto3 Bedrock client for making API calls

 Returns:
 dict: The response from the delete operation

 Raises:
 Exception: If there is an error deleting the deployment
 """

 try:
 response = bedrock_client.delete_custom_model_deployment(
 customModelDeploymentIdentifier="Deployment identifier"
)
```

```
print(f"Deployment deletion initiated")
return response

except Exception as e:
 print(f"Error deleting deployment: {str(e)}")
 raise
```

## On-demand Inferenz auf benutzerdefinierte Modelle

On-demand (OD) -Inferenz ermöglicht es Ihnen, Inferenzen für Ihre benutzerdefinierten Amazon Nova-Modelle auszuführen, ohne die bereitgestellten Durchsatzendpunkte aufrechtzuerhalten. Dies unterstützt Sie bei der Kostenoptimierung und ermöglicht eine effiziente Skalierung. Bei On-demand Inferenz werden Ihnen Gebühren auf der Grundlage der Nutzung berechnet, gemessen in Tokens, sowohl bei eingehender als auch bei ausgehender Nutzung.

### Kompatibilitätsanforderungen

Es gelten die folgenden Kompatibilitätsanforderungen:

- Die OD-Inferenz wird für Amazon Nova Pro, Lite und Micro Custom Understanding Modelle unterstützt. OD-Inferenz wird für Nova-Modelle zur benutzerdefinierten Inhaltsgenerierung nicht unterstützt.
- OD-Inferenz wird für benutzerdefinierte Understanding-Modelle von Amazon Nova unterstützt, die nach dem 16. Juli 2025 trainiert wurden. Benutzerdefinierte Modelle, die vor dem 16. Juli 2025 trainiert wurden, sind nicht mit OD-Inferenz kompatibel.
- Amazon-Bedrock-Anpassung: OD-Inferenz wird für Modelle unterstützt, die mit Amazon Bedrock angepasst wurden, sowie für Schülermodelle, die mit Amazon Bedrock aus einem Lehrmodell destilliert wurden.
- SageMaker KI-Anpassung: Für in SageMaker KI angepasste Modelle wird die OD-Inferenz nur für Parameter-efficient fein abgestimmte (PEFT) Modelle unterstützt, wenn das Modell auf Amazon Bedrock gehostet wird. Dazu gehören Direkte Präferenzoptimierung und PEFT. Die OD-Inferenz wird für fein abgestimmte Modelle nicht unterstützt. Full-rank

### Modelltraining und Inferenz

Wenn Sie nach dem 16. Juli 2025 ein neues benutzerdefiniertes Amazon Nova Pro-, Lite- oder Micro-Modell auf Amazon Bedrock oder SageMaker AI mit PEFT trainieren, ist das Modell automatisch

sowohl mit bereitgestellten als auch mit On-Demand-Inferenzoptionen kompatibel. Sie können bei der Bereitstellung Ihres Modells Ihre bevorzugte Inferenzmethode auswählen.

Um die OD-Inferenz mit einem nach dem 16. Juli 2025 trainierten Modell zu verwenden, führen Sie bitte die folgenden Schritte aus:

1. Erstellen Sie einen neuen Feinabstimmungsauftrag entweder mit der [Amazon Bedrock Customization API](#) oder der [SageMaker AI Customization API](#).
2. Stellen Sie das neu trainierte Modell mithilfe der [CreateCustomModel API](#) auf Amazon Bedrock bereit.
3. Stellen Sie es mithilfe der API für On-Demand-Inferenzen bereit. CustomModelDeployment

## Ratenbegrenzungen

Die folgenden Begrenzungen für Anfragen pro Minute (RPM) und Token pro Minute (TPM) gelten für On-Demand-Inferenzanfragen:

| Basismodell für benutzerdefiniertes Modell | Bereitstellung pro Minute pro benutzerdefiniertem Modell | TPM pro Bereitstellung eines benutzerdefinierten Modells |
|--------------------------------------------|----------------------------------------------------------|----------------------------------------------------------|
| Nova 2 Lite                                | 2.000                                                    | 4.000.000                                                |

Weitere Informationen zu den für Amazon Nova verfügbaren Kontingenten finden Sie unter [Kontingente für Amazon Nova](#).

## Latenz

Es ist mit einem Unterschied in der End-to-End-Latenz (d. h. Time To First Token, TTFT) von 20 bis 55 % zwischen dem Aufruf des Basismodells und dem Adapter zu rechnen. Der genaue Latenzwert variiert je nach Modellgröße und entspricht den Branchenstandards.

## Einschränkungen beim Anpassen von Amazon Nova-Modellen

Die Amazon Nova-Anpassung unterstützt die folgenden Funktionen nicht SageMaker.

- Aufrufen der Instance per SSH, um die Metriken zu ermitteln

Aufgrund der vorhandenen Sicherheitskontrollen können Sie keine SSH-Verbindung zum Hauptknoten in der algo-1-Trainings-Instance herstellen, um Speicher- oder NVIDIA-Statistiken zu finden und die Trainingsschritte zu validieren.

- Support für das SageMaker Trainer-SDK

SageMaker Der Trainer ist derzeit nicht verfügbar, um mit Trainingsjobs zu beginnen. Sie können Trainingsjobs derzeit nur über die Schätzer-API starten.

- Warme Pools sind für SageMaker Ausbildungsberufe nicht zugänglich

Aufgrund der vorhandenen Sicherheitskontrollen können die SageMaker warmen Pools nicht verwendet werden, um die Instanz bis zum Ende der Nutzungsdauer im warmen Pool zu belassen.

- Zusammenführen von benutzerdefinierten Modellen

Das Zusammenführen mehrerer Modelle wird derzeit nicht unterstützt. Das bedeutet, dass das Erstellen mehrerer LoRA-Adapter und die Mehrfachzusammenführung mit dem Basismodell nicht verfügbar sind.

- Unterstütztes Beobachtbarkeitstool

[TensorBoard](#) ist das einzige unterstützte Observability-Tool zur Anzeige von Kennzahlen für SageMaker Trainingsjobs. [MLflow](#) oder [WandB](#) werden derzeit nicht unterstützt. Weitere Informationen zur Verwendung von TensorBoard [TensorBoard in SageMaker SageMaker](#) finden Sie unter.

## Evaluierung mit Inspect AI

Sie können Ihre maßgeschneiderten Amazon Nova-Modelle mit [Inspect AI](#), einem Open-Source-Evaluierungsframework, bewerten. Inspect AI unterstützt standardisierte Benchmarks aus der KI-Forschungsgemeinschaft, sodass Sie die Modellleistung anhand von Wissens-, Argumentations-, Kodierungs- und Sicherheitsaufgaben messen können.

Wählen Sie den Bewertungsansatz, der am besten zu Ihrem Arbeitsablauf passt:

- Inspect AI SDK — Führen Sie Evaluierungen interaktiv von einem Notebook oder einer lokalen Umgebung aus anhand Ihres SageMaker Inferenzendpunkts durch. Ideal für Entwicklung, Iteration und schnelle Tests.

- KI-Container inspizieren — Führen Sie Evaluierungen in großem Umfang als SageMaker Schulungsjobs durch. Ideal für Pipelines zur Produktionsbewertung, die Verkettung mehrerer Benchmarks und automatisierte Workflows.

Empfohlener Arbeitsablauf: Beginnen Sie mit dem Inspect AI SDK, um Ihre benutzerdefinierten Evaluierungs-Benchmarks mithilfe der [Onboarding-Aufforderung des KI-Assistenten](#) zu erstellen und zu testen, und führen Sie dann Evaluierungen anhand Ihrer bevorzugten Inferenzlösung durch. Sobald Ihre Benchmarks vollständig validiert sind, können Sie mithilfe des Inspect AI-Containers nahtlos zur auftragsbasierten Evaluierung wechseln — ohne dass Codeänderungen erforderlich sind. Verschieben Sie einfach Ihre Benchmark-Dateien und die Rezeptdatei nach S3 und starten Sie den Job.

## Themen

- [Mit Inspect AI SDK auswerten](#)
- [Mit Inspect AI Container auswerten](#)

## Mit Inspect AI SDK auswerten

In diesem Leitfaden wird erklärt, wie Sie Ihre maßgeschneiderten Amazon Nova-Modelle, die auf SageMaker Inferenzendpunkten bereitgestellt werden, mithilfe von [Inspect AI](#), einem Open-Source-Evaluierungsframework, bewerten können.

### Note

[Praktische Anleitungen finden Sie in den Beispielnotizbüchern zu Inspect AI. SageMaker](#)

## -Übersicht

Sie können Ihre maßgeschneiderten Amazon Nova-Modelle, die auf SageMaker Endgeräten bereitgestellt werden, anhand standardisierter Benchmarks der KI-Forschungsgemeinschaft bewerten. Dieser Ansatz ermöglicht Ihnen:

- Evaluieren Sie maßgeschneiderte Amazon Nova-Modelle (fein abgestimmt, destilliert oder anderweitig angepasst) in großem Maßstab
- Führen Sie Evaluierungen mit parallel Inferenz über mehrere Endpunktinstanzen aus

- Vergleichen Sie die Modellleistung anhand von Benchmarks wie MMLU, TruthfulQA und HumanEval
- Integrieren Sie es in Ihre bestehende Infrastruktur SageMaker

## Unterstützte Modelle

Der SageMaker Inferenzanbieter arbeitet mit:

- Amazon Nova-Modelle (Nova Micro, Nova Lite, Nova Lite 2)
- Modelle, die über vLLM oder OpenAI-compatible Inferenzserver bereitgestellt werden
- Jeder Endpunkt, der das OpenAI Chat Completions API-Format unterstützt

## Voraussetzungen

Stellen Sie vor Beginn sicher, dass Sie über Folgendes verfügen:

- Und AWS-Konto mit Berechtigungen zum Erstellen und Aufrufen von Endpunkten SageMaker
- AWS Anmeldeinformationen AWS CLI, die über Umgebungsvariablen oder die IAM-Rolle konfiguriert wurden
- Python 3.9 oder höher

## Erforderliche IAM-Berechtigungen

Ihr IAM-Benutzer oder Ihre IAM-Rolle benötigt die folgenden Berechtigungen:

```
{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Effect": "Allow",
 "Action": [
 "sagemaker:InvokeEndpoint",
 "sagemaker:DescribeEndpoint"
],
 "Resource": "arn:aws:sagemaker:*:*:endpoint/*"
 }
]
}
```

## Schritt 1: Stellen Sie einen SageMaker Endpunkt bereit

Bevor Sie Evaluierungen durchführen, benötigen Sie einen SageMaker Inferenzendpunkt, auf dem Ihr Modell ausgeführt wird.

Anweisungen zum Erstellen eines SageMaker Inferenzendpunkts mit Amazon Nova-Modellen finden Sie unter [the section called “Erste Schritte”](#).

Sobald sich Ihr Endpunkt im InService Status befindet, notieren Sie sich den Endpunktnamen, der in den Evaluierungsbefehlen verwendet werden soll.

## Schritt 2: Installieren Sie die Evaluierungsabhängigkeiten

Erstellen Sie eine virtuelle Python-Umgebung und installieren Sie die erforderlichen Pakete.

```
Create virtual environment
python3.12 -m venv venv
source venv/bin/activate

Install uv for faster package installation
pip install uv

Install Inspect AI and evaluation benchmarks
uv pip install inspect-ai inspect-vals

Install AWS dependencies
uv pip install aioboto3 boto3 botocore openai
```

## Schritt 3: Konfigurieren AWS Anmeldedaten

Wählen Sie eine der folgenden Authentifizierungsmethoden:

Option 1: AWS CLI (Empfohlen)

```
aws configure
```

Geben Sie Ihre AWS Zugangsschlüssel-ID, Ihren geheimen Zugriffsschlüssel und Ihre Standardregion ein, wenn Sie dazu aufgefordert werden.

Option 2: Umgebungsvariablen

```
export AWS_ACCESS_KEY_ID=your_access_key
```



```
export AWS_SECRET_ACCESS_KEY=your_secret_key
export AWS_DEFAULT_REGION=us-west-2
```

### Option 3: IAM-Rolle

Bei Ausführung auf Amazon EC2 oder SageMaker Notebooks wird die IAM-Rolle der Instance automatisch verwendet.

Überprüfen Sie die Anmeldeinformationen

```
import boto3

sts = boto3.client('sts')
identity = sts.get_caller_identity()
print(f"Account: {identity['Account']}")
print(f>User/Role: {identity['Arn']}")
```

### Schritt 4: Laden Sie die Evaluierungs-Benchmarks herunter

Klonen Sie das Inspect Evals-Repository, um auf Standard-Benchmarks zuzugreifen:

```
git clone https://github.com/UKGovernmentBEIS/inspect_evals.git
```

Dieses Repository enthält Benchmarks wie:

- MMLU und MMLU-Pro (Wissen und Argumentation)
- TruthfulQA (Wahrhaftigkeit)
- HumanEval (Codegenerierung)
- GSM8K (mathematisches Denken)

### Schritt 5: Evaluierungen durchführen

Führen Sie eine Evaluierung mit Ihrem SageMaker Endpunkt durch:

```
cd inspect_evals/src/inspect_evals/

inspect eval mmlu_pro/mmlu_pro.py \
 --model sagemaker/my-nova-endpoint \
 -M region_name=us-west-2 \
 --max-connections 256 \
```

```
--max-retries 100 \
--display plain
```

## Die wichtigsten Parameter

| Parameter          | Standard  | Description                                                                                                               |
|--------------------|-----------|---------------------------------------------------------------------------------------------------------------------------|
| --max-connections  | 10        | Anzahl der parallel Anfragen an den Endpunkt. Skalieren Sie mit der Anzahl der Instanzen (z. B. 10 Instanzen × 25 = 250). |
| --max-retries      | 3         | Versuchen Sie es erneut mit fehlgeschlagenen Anfragen. Verwenden Sie 50-100 für umfangreiche Auswertungen.                |
| -M region_name     | us-east-1 | AWS Region, in der Ihr Endpunkt bereitgestellt wird.                                                                      |
| -M read_timeout    | 600       | Timeout in Sekunden anfordern.                                                                                            |
| -M connect_timeout | 60        | Verbindungs-Timeout in Sekunden.                                                                                          |

## Empfehlungen zur Optimierung

Für einen Endpunkt mit mehreren Instanzen:

```
10-instance endpoint example
--max-connections 250 # ~25 connections per instance
--max-retries 100 # Handle transient errors
```

Eine --max-connections zu hohe Einstellung kann den Endpunkt überfordern und zu Drosselung führen. Wenn er zu niedrig eingestellt ist, wird die Kapazität nicht ausreichend genutzt.

## Schritt 6: Ergebnisse anzeigen

Starten Sie den Inspect AI Viewer, um die Bewertungsergebnisse zu analysieren:

```
inspect view
```

Der Viewer zeigt:

- Allgemeine Punktzahlen und Kennzahlen
- Per-sample Ergebnisse mit Modellantworten
- Fehleranalyse und Fehlermuster

## Verwaltung von Endpunkten

Aktualisieren Sie einen Endpunkt

So aktualisieren Sie einen vorhandenen Endpunkt mit einem neuen Modell oder einer neuen Konfiguration:

```
import boto3

sagemaker = boto3.client('sagemaker', region_name=REGION)

Create new model and endpoint configuration
Then update the endpoint
sagemaker.update_endpoint(
 EndpointName=EXISTING_ENDPOINT_NAME,
 EndpointConfigName=NEW_ENDPOINT_CONFIG_NAME
)
```

Löschen Sie einen Endpunkt

```
sagemaker.delete_endpoint(EndpointName=ENDPOINT_NAME)
```

## Einführung benutzerdefinierter Benchmarks

Mithilfe des folgenden Workflows können Sie Inspect AI neue Benchmarks hinzufügen:

1. Studieren Sie das Datensatzformat und die Bewertungskennzahlen des Benchmarks
2. Überprüfen Sie ähnliche Implementierungen in `inspect_evals/`
3. Erstellen Sie eine Aufgabendatei, die Datensatzdatensätze in Inspect AI-Beispiele konvertiert
4. Implementieren Sie geeignete Solver und Scorer
5. Validieren Sie mit einem kleinen Testlauf

Beispiel für eine Aufgabenstruktur:

```
from inspect_ai import Task, task
from inspect_ai.dataset import hf_dataset
from inspect_ai.scorer import choice
from inspect_ai.solver import multiple_choice

@task
def my_benchmark():
 return Task(
 dataset=hf_dataset("dataset_name", split="test"),
 solver=multiple_choice(),
 scorer=choice()
)
```

## Fehlerbehebung

### Häufig auftretende Probleme

#### Drosselung oder Timeouts an Endpunkten

- Reduzieren `--max-connections`
- Erhöhen `--max-retries`
- Überprüfen Sie die CloudWatch Endpunktkennzahlen auf Kapazitätsprobleme

#### Fehler bei der Authentifizierung

- Stellen Sie sicher, dass die AWS Anmeldeinformationen korrekt konfiguriert sind
- Überprüfen Sie, ob die IAM-Berechtigungen Folgendes beinhalten `sagemaker:InvokeEndpoint`

#### Fehler im Modell

- Stellen Sie sicher, dass sich der Endpunkt im InService Status befindet
- Stellen Sie sicher, dass das Modell das OpenAI Chat Completions API-Format unterstützt

## Zugehörige Ressourcen

- [Untersuchen Sie die KI-Dokumentation](#)
- [Untersuchen Sie das Evals Repository](#)
- [SageMaker Entwicklerhandbuch](#)

- [Stellen Sie Modelle für Inferenz bereit](#)
- [Konfiguration des AWS CLI](#)

## Mit Inspect AI Container auswerten

Der SageMaker Inspect AI-Container führt LLM-Modellevaluierungen für SageMaker Schulungsjobs durch. Der Container verwendet [Inspect AI](#), um einen standardisierten Bewertungsprozess für Modelle bereitzustellen, die auf SageMaker Inferenzendpunkten oder Amazon Bedrock eingesetzt werden — einschließlich der Modelle Amazon Nova 1.0 (Micro, Lite, Pro) und 2.0 (Lite 2).

Frühere [Bewertungsansätze](#) (basierend auf [Ligtheval](#)) verknüpften Offline-Inferenz- und Bewertungslogik eng miteinander, was die Flexibilität bei der Bereitstellung und Prüfung von Modellen einschränkte. Der Inspect AI-Container entkoppelt die Bewertungslogik vollständig von der Inferenz.

### -Übersicht

Zu den wichtigsten Vorteilen gehören:

- Bringen Sie Ihre eigenen Benchmarks mit — schreiben Sie Bewertungsaufgaben im Inspect AI-Format und fügen Sie dann domänenspezifische Bewertungsaufgaben hinzu, ohne auf ein zentrales Team angewiesen zu sein, um sie zu integrieren.
- Evaluieren Sie mit verschiedenen Inferenzoptionen — funktioniert mit SageMaker Inference (vorhandener Endpunkt oder On-the-fly erstellen), Amazon Bedrock und weiteren eingehenden Inferenz-Backends.
- Iterieren Sie schneller — gehen Sie ohne Änderungen an der Infrastruktur von der Benchmark-Entwicklung zur Produktionsevaluierung über. Das Onboarding neuer Benchmarks, das zuvor Tage gedauert hat, erfolgt innerhalb von Minuten.
- Skalierbare Ausführung — verketteten Sie mehrere Benchmarks in einem Job, kombinieren Sie Standard-Benchmarks aus der Inspect-Evals-Bibliothek mit Ihren eigenen benutzerdefinierten Aufgaben im selben Job.
- Ein Einstiegspunkt für alle Trainingstechniken — unabhängig davon, ob Ihr Modell mit SFT (SMTJ, SMHP), CPT (SMHP) oder RFT (SMTJ, SMHP) optimiert wurde, der Container bewertet es über dieselbe Schnittstelle. Die Auswertung von Checkpoints während des Trainings, die in bestimmten Schritten gespeichert wurden, wird ebenfalls unterstützt (z. B. Schritt 500, Schritt 1000), indem auf den Checkpoint-Pfad verwiesen wird. `model_s3_uri`

## Funktionsweise

Sie geben zwei Eingaben in den Container ein:

1. Eine YAML-Konfigurationsdatei (Rezept), die den Inferenzanbieter, die Benchmarks und die Bewertungsparameter definiert
2. Benchmark-Dateien (Python-Skripte mit dem `@task Decorator`), die auf Amazon S3 hochgeladen wurden

Der Container kümmert sich um die Endpunktverwaltung, die Ausführung der Evaluierung und die Erfassung der Ergebnisse. Wenn der Trainingsjob abgeschlossen ist, werden die Ergebnisse an den angegebenen S3-Ausgabespeicherort geschrieben.

## Container-Bild

In der folgenden Tabelle sind die Inspect AI-Container-Image-URLs nach AWS Regionen aufgeführt.

| Region    | URI für das Container-Image                                                  |
|-----------|------------------------------------------------------------------------------|
| us-east-1 | 763104351884.dkr.ecr.us-east-1.amazonaws.com/<br>sagemaker-inspect-ai:latest |
| us-west-2 | 763104351884.dkr.ecr.us-west-2.amazonaws.com/<br>sagemaker-inspect-ai:latest |
| eu-west-2 | 763104351884.dkr.ecr.eu-west-2.amazonaws.com/<br>sagemaker-inspect-ai:latest |

## Voraussetzungen

Bevor Sie beginnen, stellen Sie sicher, dass Sie über die folgenden Ressourcen und den folgenden Zugriff verfügen.

| Anforderung                     | Description                                                                            |
|---------------------------------|----------------------------------------------------------------------------------------|
| AWS Konto mit SageMaker Zugriff | Ein aktives Mitglied AWS-Konto mit der Erlaubnis, SageMaker Schulungsjobs zu erstellen |

| Anforderung                                            | Description                                                                                                                                                                                |
|--------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| S3-Bucket                                              | Ein Bucket zum Speichern Ihrer Bewertungsrezepte, Benchmark-Dateien und Ausgabeergebnisse                                                                                                  |
| IAM-Ausführungsrolle                                   | Eine Rolle, die den Zugriff auf Ihre Ressourcen übernehmen SageMaker kann                                                                                                                  |
| SageMaker Inferenzendpunkt oder Amazon Bedrock-Zugriff | Ein bereitgestellter Modellendpunkt oder Amazon Bedrock-Modellzugriff für das Modell, das Sie evaluieren möchten                                                                           |
| AWS CLI oder SageMaker Python SDK                      | Tools zum Einreichen von Schulungsaufträgen und zum Verwalten von Ressourcen                                                                                                               |
| Kapazitätsreservierung (große Modelle)                 | Wenden Sie sich für Modelle, die beschleunigte Instances benötigen (z. B. p5 für Nova Lite 2), an den AWS Support, um Kapazität für SageMaker Inference oder Amazon Bedrock zu reservieren |

## Schritt 1: Richten Sie IAM-Berechtigungen ein

Der SageMaker Trainingsjob wird unter einer Ausführungsrolle ausgeführt, die Sie angeben. Diese Rolle benötigt Berechtigungen zum Lesen von Benchmarks aus S3, zum Schreiben von Ergebnissen, zum Aufrufen des Inferenzendpunkts und zum Schreiben von Protokollen. CloudWatch

### 1.1 Erstellen Sie die Vertrauensrichtlinie

Speichern Sie Folgendes unter `trust_policy.json`:

```
{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Effect": "Allow",
 "Principal": {
 "Service": "sagemaker.amazonaws.com"
 },
 "Action": "sts:AssumeRole"
 }
]
}
```

```
}
```

## 1.2 Erstellen Sie die Rolle

```
aws iam create-role \
 --role-name InspectLensEvalRole \
 --assume-role-policy-document file://trust_policy.json
```

## 1.3 Hängen Sie die Berechtigungsrichtlinie an

Speichern Sie Folgendes unter `eval_policy.json` und ersetzen Sie alle Platzhalterwerte (REGION,ACCOUNT\_ID, Bucket-Namen) durch Ihre Werte:

```
{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Sid": "S3ReadBenchmarkData",
 "Effect": "Allow",
 "Action": ["s3:GetObject", "s3:ListBucket"],
 "Resource": [
 "arn:aws:s3:::YOUR_BENCHMARK_BUCKET",
 "arn:aws:s3:::YOUR_BENCHMARK_BUCKET/*"
]
 },
 {
 "Sid": "S3WriteResults",
 "Effect": "Allow",
 "Action": ["s3:GetObject", "s3:PutObject", "s3:ListBucket"],
 "Resource": [
 "arn:aws:s3:::YOUR_RESULTS_BUCKET",
 "arn:aws:s3:::YOUR_RESULTS_BUCKET/*"
]
 },
 {
 "Sid": "SageMakerInvokeExistingEndpoint",
 "Effect": "Allow",
 "Action": [
 "sagemaker:InvokeEndpoint",
 "sagemaker:InvokeEndpointWithResponseStream",
 "sagemaker:DescribeEndpoint"
],
 "Resource": "arn:aws:sagemaker:REGION:ACCOUNT_ID:endpoint/*"
```



```

},
{
 "Sid": "BedrockInference",
 "Effect": "Allow",
 "Action": [
 "bedrock:InvokeModel",
 "bedrock:InvokeModelWithResponseStream"
],
 "Resource": [
 "arn:aws:bedrock:REGION::foundation-model/*",
 "arn:aws:bedrock:REGION:ACCOUNT_ID:inference-profile/*",
 "arn:aws:bedrock:REGION:ACCOUNT_ID:provisioned-model/*",
 "arn:aws:bedrock:REGION:ACCOUNT_ID:custom-model/*",
 "arn:aws:bedrock:REGION:ACCOUNT_ID:imported-model/*",
 "arn:aws:bedrock:REGION:ACCOUNT_ID:custom-model-deployment/*"
]
},
{
 "Sid": "BedrockCustomModelAccess",
 "Effect": "Allow",
 "Action": [
 "bedrock:GetCustomModel",
 "bedrock:GetImportedModel",
 "bedrock:GetProvisionedModelThroughput",
 "bedrock:GetCustomModelDeployment",
 "bedrock:GetInferenceProfile"
],
 "Resource": [
 "arn:aws:bedrock:REGION:ACCOUNT_ID:custom-model/*",
 "arn:aws:bedrock:REGION:ACCOUNT_ID:imported-model/*",
 "arn:aws:bedrock:REGION:ACCOUNT_ID:provisioned-model/*",
 "arn:aws:bedrock:REGION:ACCOUNT_ID:custom-model-deployment/*",
 "arn:aws:bedrock:REGION:ACCOUNT_ID:inference-profile/*"
]
},
{
 "Sid": "SageMakerCreateEndpointLifecycle",
 "Effect": "Allow",
 "Action": [
 "sagemaker:CreateModel",
 "sagemaker:DescribeModel",
 "sagemaker>DeleteModel",
 "sagemaker:CreateEndpointConfig",
 "sagemaker:DescribeEndpointConfig",

```

```

 "sagemaker:DeleteEndpointConfig",
 "sagemaker:CreateEndpoint",
 "sagemaker:DescribeEndpoint",
 "sagemaker:DeleteEndpoint",
 "sagemaker:InvokeEndpoint",
 "sagemaker:InvokeEndpointWithResponseStream"
],
 "Resource": [
 "arn:aws:sagemaker:REGION:ACCOUNT_ID:model/inspectlens-*",
 "arn:aws:sagemaker:REGION:ACCOUNT_ID:endpoint/inspectlens-*",
 "arn:aws:sagemaker:REGION:ACCOUNT_ID:endpoint-config/inspectlens-*"
]
},
{
 "Sid": "ECRAuth",
 "Effect": "Allow",
 "Action": "ecr:GetAuthorizationToken",
 "Resource": "*"
},
{
 "Sid": "PassRoleToSageMaker",
 "Effect": "Allow",
 "Action": "iam:PassRole",
 "Resource": "arn:aws:iam::ACCOUNT_ID:role/InspectLensEvalRole",
 "Condition": {
 "StringEquals": {
 "iam:PassedToService": "sagemaker.amazonaws.com"
 }
 }
},
{
 "Sid": "VPCNetworkingForEndpoint",
 "Effect": "Allow",
 "Action": [
 "ec2:CreateNetworkInterface",
 "ec2:CreateNetworkInterfacePermission",
 "ec2:DeleteNetworkInterface",
 "ec2:DeleteNetworkInterfacePermission",
 "ec2:DescribeNetworkInterfaces",
 "ec2:DescribeVpcs",
 "ec2:DescribeDhcpOptions",
 "ec2:DescribeSubnets",
 "ec2:DescribeSecurityGroups"
]
},

```

```

 "Resource": "*"
 },
 {
 "Sid": "CloudWatchLogs",
 "Effect": "Allow",
 "Action": [
 "logs:CreateLogGroup",
 "logs:CreateLogStream",
 "logs:PutLogEvents",
 "logs:DescribeLogStreams"
],
 "Resource": [
 "arn:aws:logs:REGION:ACCOUNT_ID:log-group:/aws/sagemaker/TrainingJobs:*",
 "arn:aws:logs:REGION:ACCOUNT_ID:log-group:/aws/sagemaker/Endpoints/*"
]
 },
 {
 "Sid": "MLflowTrackingServer",
 "Effect": "Allow",
 "Action": [
 "sagemaker:DescribeMlflowTrackingServer",
 "sagemaker:CreatePresignedMlflowTrackingServerUrl"
],
 "Resource": "arn:aws:sagemaker:REGION:ACCOUNT_ID:mlflow-tracking-server/*"
 },
 {
 "Sid": "MLflowTrackingOperations",
 "Effect": "Allow",
 "Action": [
 "sagemaker-mlflow:AccessUI",
 "sagemaker-mlflow:CreateExperiment",
 "sagemaker-mlflow:GetExperiment",
 "sagemaker-mlflow:GetExperimentByName",
 "sagemaker-mlflow:SearchExperiments",
 "sagemaker-mlflow:CreateRun",
 "sagemaker-mlflow:GetRun",
 "sagemaker-mlflow:UpdateRun",
 "sagemaker-mlflow:SearchRuns",
 "sagemaker-mlflow:LogMetric",
 "sagemaker-mlflow:LogParam",
 "sagemaker-mlflow:LogBatch",
 "sagemaker-mlflow:SetTag",
 "sagemaker-mlflow:LogArtifact",
 "sagemaker-mlflow:ListArtifacts"
]
 }
}

```

```

],
 "Resource": "arn:aws:sagemaker:REGION:ACCOUNT_ID:mlflow-tracking-server/*"
 },
 {
 "Sid": "KMSForVolumeEncryption",
 "Effect": "Allow",
 "Action": [
 "kms:Encrypt",
 "kms:Decrypt",
 "kms:GenerateDataKey",
 "kms:CreateGrant",
 "kms:DescribeKey"
],
 "Resource": "arn:aws:kms:REGION:ACCOUNT_ID:key/*"
 }
]
}

```

Fügen Sie die Richtlinie an die Rolle an:

```

aws iam put-role-policy \
 --role-name InspectLensEvalRole \
 --policy-name InspectLensEvalPolicy \
 --policy-document file://eval_policy.json

```

## Schritt 2: Schreiben Sie Ihr Evaluationsrezept

Das Eval-Rezept ist eine YAML-Konfigurationsdatei, die definiert, wie der Container Ihre Evaluierungen ausführt. Das Rezept spezifiziert den Inferenzanbieter, die Benchmarks, die Evaluierungsparameter und die Ausgabeeinstellungen.

Ausführliche Beispiele finden Sie in den folgenden Notizbüchern:

- [Evaluieren Sie einen vorhandenen SageMaker Endpunkt](#)
- [Evaluieren Sie mit einem verwalteten Endpunkt](#)
- [Evaluieren Sie ein Amazon Bedrock-Modell](#)

### Option A: Evaluieren Sie einen vorhandenen Endpunkt SageMaker

Verwenden Sie diese Option, wenn Sie bereits ein Modell auf einem SageMaker Inferenzendpunkt implementiert haben.

```
inference_provider:
 sagemaker_endpoint:
 endpoint_name: "my-existing-endpoint"
 region: "us-east-1"

benchmarks:
 s3_path: "s3://your-bucket/benchmarks/my_benchmarks/"
 tasks:
 - name: mmlu

eval:
 max_connections: 10
 max_retries: 100
 timeout: 600

output:
 s3_path: "s3://your-bucket/eval-results/"
```

### Option B: Endpunkt erstellen, auswerten und dann bereinigen

Verwenden Sie diese Option, damit der Container ein Amazon Nova-Basismodell oder ein fein abgestimmtes Modell bereitstellt, Evaluierungen durchführt und den Endpunkt automatisch herunterfährt. Dies ist der empfohlene Ansatz für einmalige Evaluierungsläufe. Rufen Sie den neuesten SageMaker Inferenzcontainer aus der [Amazon Nova SageMaker Inference Container-Image-Dokumentation](#) ab.

```
inference_provider:
 sagemaker_endpoint:
 endpoint_name: null # null = create new endpoint
 model_s3_uri: "s3://your-bucket/models/nova-micro/"
 inference_image_uri: "708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-inference-
repo:SM-Inference-latest"
 instance_type: "ml.p5.48xlarge"
 instance_count: 1
 execution_role_arn: "arn:aws:iam::ACCOUNT_ID:role/InspectLensEvalRole"
 region: "us-east-1"
 context_length: "16000"
 max_concurrency: "32"
 cleanup_endpoint: true # Auto-delete after eval

benchmarks:
 s3_path: "s3://your-bucket/benchmarks/my_benchmarks/"
```

```
tasks:
 - name: mmlu_pro
 - name: arc_c
 - name: boolq

eval:
 fail_on_error: false
 decoding:
 temperature: 0.0
 top_p: 1.0
 top_k: -1
 max_tokens: 16000
 reasoning_effort: null
 max_connections: 16
 max_retries: 100
 timeout: 600
 extra_args:
 - "-M"
 - "completion_mode=True"
 - "--logprobs"
 - "--top-logprobs"
 - "5"

output:
 s3_path: "s3://your-bucket/eval-results/"
```

### Hinweis zu: **model\_s3\_uri**

- Amazon Nova GA-Modelle (Basis-Checkpoints): Zum Beispiel `s3://escrow-nova-model-708977205387-us-east-1/nova-lite-2/prod/` — SageMaker verwaltet den Zugriff automatisch, es sind keine zusätzlichen S3-Berechtigungen erforderlich.
- Maßgeschneiderte Amazon Nova-Modelle (Checkpoints nach dem Training): `s3://customer-escrow-ACCOUNT_ID-SUFFIX/YOUR_RUN_NAME/outputs/checkpoints/step_N/` — Dies ist der Escrow-Bucket-Pfad aus Ihrer Trainingsjob-Ausgabe.

### Option C: Evaluieren über Amazon Bedrock

Verwenden Sie diese Option, um ein über Amazon Bedrock verfügbares Modell zu evaluieren, ohne einen Endpunkt verwalten zu müssen.

```
inference_provider:
```

```
bedrock:
 model_id: amazon.nova-pro-v1:0
 region: us-east-1

benchmarks:
 - name: mmlu
 path: benchmarks/mmlu_pro.py
 limit: 100

eval:
 fail_on_error: false
 decoding:
 temperature: 0.0
 top_p: 1.0
 top_k: -1
 max_tokens: 8192
 reasoning_effort: null
 max_connections: 10
 max_retries: 50
 timeout: 600
 extra_args:
 - "--display"
 - "plain"

output:
 s3_path: s3://your-bucket/eval/output/
```

## Benchmarks-Konfiguration

**benchmarks**In diesem Abschnitt wird definiert, welche Bewertungsaufgaben ausgeführt werden sollen. Sie können mehrere Benchmarks in einem einzigen Job verketten.

| Feld | Erforderlich | Standard | Description                                                                 |
|------|--------------|----------|-----------------------------------------------------------------------------|
| name | Ja           | —        | Ein aussagekräftiger Name für den Benchmark-Lauf                            |
| path | Ja           | —        | Relativer Pfad zur Benchmark-Python-Datei in Ihrem S3-Benchmark-Verzeichnis |

| Feld                   | Erforderlich | Standard               | Description                                                                                    |
|------------------------|--------------|------------------------|------------------------------------------------------------------------------------------------|
| <code>limit</code>     | Nein         | Keine (alle Beispiele) | Maximale Anzahl der auszuwertenden Proben. Zum Testen vor vollständigen Durchläufen verwenden. |
| <code>epochs</code>    | Nein         | 1                      | Häufigkeit, mit der die Auswertung auf statistische Signifikanz wiederholt werden soll         |
| <code>task_args</code> | Nein         | —                      | Key-value Paare, die als Argumente an die Benchmark-Aufgabenfunktion übergeben wurden          |

## Eval-Konfiguration

Der `eval` Abschnitt steuert, wie der Container Evaluierungen durchführt.

| Parameter                    | Erforderlich | Standard           | Description                                                                                                        |
|------------------------------|--------------|--------------------|--------------------------------------------------------------------------------------------------------------------|
| <code>fail_on_error</code>   | Nein         | <code>false</code> | Beenden Sie die Auswertung, wenn eine Probe fehlschlägt. <code>true</code> Für strikte Validierung auf einstellen. |
| <code>max_connections</code> | Nein         | 10                 | Anzahl der parallel Anfragen an den Inferenzendpunkt                                                               |
| <code>max_retries</code>     | Nein         | 3                  | Anzahl der Wiederholungsversuche für fehlgeschlagene Inferenzanfragen                                              |
| <code>timeout</code>         | Nein         | 600                | Anforderungs-Timeout in Sekunden für jeden Inferenzaufruf                                                          |
| <code>extra_args</code>      | Nein         | —                  | Zusätzliche Schlüssel-Wert-Paare werden direkt an den Befehl <code>Inspect AI eval</code> übergeben                |



## Parameter dekodieren

Konfigurieren Sie die Parameter für die Modelldekodierung im `eval.decoding` Abschnitt:

| Parameter                     | Erforderlich | Standard | Description                                                                                                                                                                                                      |
|-------------------------------|--------------|----------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <code>temperature</code>      | Nein         | 0.0      | Steuert die Zufälligkeit bei der Generierung. Wird <code>0.0</code> für deterministische, reproduzierbare Benchmark-Ergebnisse verwendet.                                                                        |
| <code>top_p</code>            | Nein         | 1,0      | Schwellenwert für die Kernprobenahme. <code>1.0</code> bedeutet keine Einschränkung.                                                                                                                             |
| <code>top_k</code>            | Nein         | -1       | Beschränkt die Wortwahl auf die K wahrscheinlichsten Tokens. <code>-1</code> deaktiviert diesen Filter.                                                                                                          |
| <code>max_tokens</code>       | Nein         | 8192     | Maximale Anzahl von Token, die pro Antwort generiert werden können. Erhöhung bei Benchmarks, die lange Argumentationsketten erfordern.                                                                           |
| <code>reasoning_effort</code> | Nein         | Null     | Steuert die Argumentationstiefe für Modelle, die dies unterstützen (z. B. Amazon Nova-Modelle mit erweitertem Denken). Optionen: <code>low</code> , <code>high</code> , oder <code>null</code> zum Deaktivieren. |

## Konfiguration der Ausgabe

`output` In diesem Abschnitt wird definiert, wo und wie die Bewertungsergebnisse gespeichert werden.

| Feld                 | Erforderlich | Standard | Description                                                |
|----------------------|--------------|----------|------------------------------------------------------------|
| <code>s3_path</code> | Ja           | —        | S3-URI, in den die Bewertungsergebnisse geschrieben werden |

| Feld          | Erforderlich | Standard | Description                                                                   |
|---------------|--------------|----------|-------------------------------------------------------------------------------|
| output_format | Nein         | eval     | Format für Ergebnisdateien. Die Optionen finden Sie in der folgenden Tabelle. |

Die folgenden Ausgabeformate sind verfügbar:

| Format | Description                                                                                   |
|--------|-----------------------------------------------------------------------------------------------|
| eval   | Natives Inspect AI-Format. Kompatibel mit <code>inspect view</code> für interaktive Analysen. |
| csv    | Comma-separated Werte. Geeignet für Tabellenkalkulationsanalysen und Daten-Pipelines.         |
| jsonl  | Format der JSON-Zeilen. Ein JSON-Objekt pro Zeile für die Streaming-Verarbeitung.             |
| json   | Standard-JSON-Format. Vollständige Ergebnisse in einer einzigen strukturierten Datei.         |

## MLflow-Konfiguration

Optional können Sie Bewertungsmetriken auf einem MLFlow-Tracking-Server protokollieren. Fügen Sie den `tracking` Abschnitt zu Ihrem Rezept hinzu:

```
tracking:
 mlflow_tracking_arn: null # ARN of SageMaker MLflow tracking server
 mlflow_experiment_name: "inspectlens" # experiment name
 mlflow_tracing: true # log full request/response traces
 mlflow_log_artifacts: true # upload .eval files to MLflow
```

| Feld                                | Erforderlich | Standard             | Description                                                                                                                                                                         |
|-------------------------------------|--------------|----------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <code>mlflow_tracking_arn</code>    | Nein         | Null                 | ARN Ihres SageMaker MLFlow-Tracking-Servers. Diese Einstellung aktiviert die MLflow-Protokollierung. Auslassen oder auf <code>setzen</code> , um <code>null</code> zu deaktivieren. |
| <code>mlflow_experiment_name</code> | Nein         | inspiziert die Linse | Name des MLflow-Experiments, unter dem Läufe protokolliert werden sollen.                                                                                                           |
| <code>mlflow_tracing</code>         | Nein         | <code>true</code>    | Wenn <code>true</code> , protokolliert die vollständigen request/response Spuren für jede Probe.                                                                                    |
| <code>mlflow_log_artifacts</code>   | Nein         | <code>true</code>    | Wenn <code>true</code> , lädt <code>.eval</code> Protokolldateien als MLflow-Artefakte hoch.                                                                                        |

## Vollständige Rezeptreferenz

Das folgende Beispiel zeigt ein vollständiges Rezept mit allen verfügbaren Konfigurationsoptionen:

```
inference_provider:
 sagemaker_endpoint:
 endpoint_name: my-nova-endpoint
 model_s3_uri: s3://your-bucket/models/my-model/
 inference_image_uri: "708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-inference-repo:SM-Inference-latest"
 instance_type: ml.g5.12xlarge
 cleanup_endpoint: true
 region: us-west-2

benchmarks:
 - name: mmlu
 path: benchmarks/mmlu_pro.py
 limit: 100
 epochs: 3
 task_args:
 subject: math
 - name: truthfulqa
 path: benchmarks/truthfulqa.py
```

```
 limit: 50

eval:
 fail_on_error: false
 decoding:
 temperature: 0.0
 top_p: 1.0
 top_k: -1
 max_tokens: 8192
 reasoning_effort: null
 max_connections: 256
 max_retries: 50
 timeout: 600
 extra_args:
 - "--display"
 - "plain"

output:
 s3_path: s3://your-bucket/eval/output/
 output_format: eval

tracking:
 mlflow_tracking_arn: "arn:aws:sagemaker:us-west-2:123456789012:mlflow-tracking-server/my-server"
 mlflow_experiment_name: "inspectlens"
 mlflow_tracing: true
 mlflow_log_artifacts: true
```

### Schritt 3: Bereiten Sie die Benchmark-Dateien vor

Benchmarks sind Python-Dateien, die den `Inspect @task AI-Decorator` verwenden, um Bewertungsaufgaben zu definieren. Das [inspect-evals Repository bietet mehr als 128](#) gebrauchsfertige Benchmarks, oder Sie können Ihre eigenen schreiben.

#### Beispiel-Benchmark

Das folgende Beispiel zeigt einen Minimal-Benchmark, der die Multiple-Choice-Leistung für einen Datensatz bewertet: HuggingFace

```
from inspect_ai import task, Task
from inspect_ai.dataset import hf_dataset
from inspect_ai.scorer import choice
from inspect_ai.solver import multiple_choice
```

```
@task
def my_benchmark():
 return Task(
 dataset=hf_dataset(
 path="cais/mmlu",
 name="abstract_algebra",
 split="test",
),
 solver=multiple_choice(),
 scorer=choice(),
)
```

## Abhängigkeiten

Wenn Ihr Benchmark zusätzliche Abhängigkeiten benötigt, fügen Sie ein `pyproject.toml` oder `requirements.txt` in dasselbe S3-Verzeichnis ein:

```
[project]
name = "my-benchmark"
version = "0.1.0"
requires-python = ">=3.12"
dependencies = [
 "datasets>=2.14.0",
]
```

## Pre-installed Pakete

Der Container enthält die folgenden Pakete. Sie müssen diese nicht in Ihrem `pyproject.toml` auflisten.

| Package     | Version |
|-------------|---------|
| Python      | 3.12    |
| inspizieren | 0.3.220 |
| boto3       | 1,40,61 |
| Aioboto 3   | 15.5.0  |

| Package | Version |
|---------|---------|
| Openai  | 2.36.0  |
| mlflow  | 3.12.0  |
| Pyyaml  | 6.0.3   |

## Auswahl der Aufgabe

Das `tasks` Feld in Ihrem Rezept steuert, welche Aufgaben innerhalb einer Benchmark-Datei ausgeführt werden sollen.

| Konfiguration   | Beispiel                        | Behavior                                                              |
|-----------------|---------------------------------|-----------------------------------------------------------------------|
| Leer tasks      | <code>tasks: []</code>          | Führt alle in der Benchmark-Datei definierten Aufgaben aus            |
| Filter benennen | <code>tasks: ["algebra"]</code> | Führt Aufgaben aus, deren Name die Teilzeichenfolge „Algebra“ enthält |
| limit           | <code>limit: 50</code>          | Begrenzt die Anzahl der pro Aufgabe ausgewerteten Stichproben         |
| epochs          | <code>epochs: 3</code>          | Wiederholt die Auswertung mehrmals, um die Varianz zu messen          |

## Schritt 4: Bereiten Sie Ihre S3-Struktur vor

Die folgende Struktur ist eine Empfehlung für die Organisation von Konfigurationen, Benchmarks und Ergebnissen. Sie können den Container auf eine beliebige S3-Position richten — die Struktur selbst ist nicht erforderlich.

```
s3://your-bucket/
config/
inspect_config.yaml # Your eval recipe
benchmarks/
my_benchmarks/ # Your benchmark Python files
pyproject.toml # Optional: benchmark dependencies
```

```
my_task.py # @task decorated functions
_helpers.py # Shared utilities
output/ # Results written here
```

Laden Sie Ihre Dateien auf S3 hoch:

```
Upload benchmark files
aws s3 cp my_benchmarks/ s3://your-bucket/benchmarks/my_benchmarks/ --recursive

Upload your eval recipe
aws s3 cp inspect_config.yaml s3://your-bucket/config/inspect_config.yaml
```

## Schritt 5: Reichen Sie den Ausbildungsjob ein

Reichen Sie einen SageMaker Schulungsjob ein, um Ihre Bewertung durchzuführen. Sie können das AWS CLI oder das SageMaker Python-SDK verwenden.

### Option A: AWS CLI

```
aws sagemaker create-training-job \
 --training-job-name inspect-eval-$(date +%Y%m%d-%H%M%S) \
 --algorithm-specification \
 TrainingImage=763104351884.dkr.ecr.us-east-1.amazonaws.com/sagemaker-inspect-
ai:latest,TrainingInputMode=File \
 --role-arn arn:aws:iam::123456789012:role/SageMakerInspectAIRole \
 --resource-config \
 InstanceType=ml.m5.large,InstanceCount=1,VolumeSizeInGB=30 \
 --stopping-condition MaxRuntimeInSeconds=86400 \
 --input-data-config '[
 {
 "ChannelName": "config",
 "DataSource": {
 "S3DataSource": {
 "S3DataType": "S3Prefix",
 "S3Uri": "s3://your-bucket/eval/config/",
 "S3DataDistributionType": "FullyReplicated"
 }
 }
 }
]' \
 --output-data-config S3OutputPath=s3://your-bucket/eval/output/ \
 --region us-west-2
```

## Option B: SageMaker Python-SDK V3

```
from sagemaker.train import ModelTrainer
from sagemaker.train.configs import InputData, Compute
from sagemaker.core.shapes.shapes import StoppingCondition, OutputDataConfig

trainer = ModelTrainer(
 training_image="763104351884.dkr.ecr.us-east-1.amazonaws.com/sagemaker-inspect-ai:latest",
 compute=Compute(
 instance_type="ml.m5.large",
 instance_count=1,
 volume_size_in_gb=30,
),
 output_data_config=OutputDataConfig(
 s3_output_path="s3://your-bucket/eval/output/"
),
 role="arn:aws:iam::123456789012:role/SageMakerInspectAIRole",
 stopping_condition=StoppingCondition(max_runtime_in_seconds=86400),
)

trainer.train(
 input_data_config=[
 InputData(
 channel_name="config",
 data_source="s3://your-bucket/eval/config/",
)
]
)
```

### Die wichtigsten Parameter

| Parameter     | Wert                                                                     | Description                                         |
|---------------|--------------------------------------------------------------------------|-----------------------------------------------------|
| TrainingImage | 763104351884.dkr.ecr.us-east-1.amazonaws.com/sagemaker-inspect-ai:latest | Das Inspect AI-Container-Image                      |
| InstanceType  | ml.m5.large                                                              | Orchestrator-Instanztyp (nicht die Inferenzinstanz) |



| Parameter           | Wert   | Description                                                   |
|---------------------|--------|---------------------------------------------------------------|
| VolumeSizeInGB      | 30     | Speicher für Benchmark-Daten und -Protokolle                  |
| MaxRuntimeInSeconds | 86400  | Maximale Auftragsdauer (24 Stunden)                           |
| ChannelName         | config | Eingangskanal, der Ihre Rezept- und Benchmark-Dateien enthält |

## Anleitung zum Orchestrator-Instanztyp

In der Trainingsjob-Instanz wird die Orchestrierungslogik für die Evaluierung ausgeführt, nicht die Modellinferenz. Wählen Sie einen Instanztyp, der auf Ihrem Evaluierungs-Workload basiert.

| Instance-Typ  | Anwendungsfall         | Empfehlung                                                                               |
|---------------|------------------------|------------------------------------------------------------------------------------------|
| ml.m5.large   | Empfohlener Standard   | Ausreichend für die meisten Evaluierungs-Workloads mit mäßiger Parallelität              |
| ml.m5.4xlarge | Große Benchmark-Suiten | Wird verwendet, wenn viele Benchmarks mit hohen max_connections Werten ausgeführt werden |
| ml.c5.large   | Cost-sensitive         | Kostengünstigere Alternative für einfache Evaluierungen mit geringer Parallelität        |

## Umgebungsvariablen

Sie können Umgebungsvariablen zur Authentifizierung oder Konfiguration an den Container übergeben. Fügen Sie dem AWS CLI Befehl den `--environment` Parameter hinzu:

```
aws sagemaker create-training-job \
...
--environment '{
 "HF_TOKEN": "hf_your_token_here",
 "HF_HUB_DOWNLOAD_TIMEOUT": "300"
}
```

```
}'
```

## Schritt 6: Überwachen Sie den Job

Nachdem Sie den Schulungsjob eingereicht haben, können Sie dessen Fortschritt anhand der CloudWatch Protokolle AWS CLI oder verfolgen.

### Überprüfen Sie den Jobstatus

```
aws sagemaker describe-training-job \
 --training-job-name your-job-name \
 --query "TrainingJobStatus" \
 --output text
```

### Streamen Sie Protokolle

```
aws logs tail /aws/sagemaker/TrainingJobs \
 --log-stream-name-prefix your-job-name \
 --follow
```

### Was erwartet Sie in Logs

Die Container-Logs zeigen den Fortschritt in den folgenden Phasen:

1. Start — Container-Initialisierung und Konfigurationsvalidierung
2. Benchmark-Download — Benchmark-Dateien werden heruntergeladen und Abhängigkeiten installiert
3. Endpunkt-Setup — Den Inferenz-Endpunkt erstellen oder eine Verbindung zu ihm herstellen
4. Bewertung — Ausführung von Benchmark-Aufgaben mit Fortschrittsindikatoren
5. Ergebnisse hochladen — Ergebnisse in S3 schreiben und optional in MLflow protokollieren
6. Säuberung — Temporäre Endpunkte werden gelöscht, wenn `cleanup_endpoint: true`

### Geschätzte Zeitpläne

| Stage                | Geschätzte Dauer |
|----------------------|------------------|
| Start des Containers | 2—5 Minuten      |

| Stage                                        | Geschätzte Dauer                                  |
|----------------------------------------------|---------------------------------------------------|
| Erstellung von Endpunkten (falls zutreffend) | 15—30 Minuten                                     |
| Bewertung                                    | Variiert je nach Benchmark-Größe und Modelllatenz |
| Bereinigen                                   | 1—2 Minuten                                       |

## Schritt 7: Ergebnisse anzeigen und interpretieren

Sehen Sie sich nach Abschluss des Jobs Ihre Bewertungsergebnisse an.

### Mit Inspect AI anzeigen

Verwenden Sie den Inspect AI-Viewer, um interaktiv Ergebnisse direkt aus S3 heraus zu untersuchen:

```
inspect view --log-dir s3://your-bucket/eval-results/
```

Dieser Befehl öffnet eine lokale Weboberfläche, in der Sie Ergebnisse durchsuchen, einzelne Stichproben ansehen und Durchläufe vergleichen können.

### Herunterladen und teilen

So laden Sie Ergebnisse lokal herunter:

```
aws s3 cp s3://your-bucket/eval/output/ ./results/ --recursive
```

```
INSPECT_LOG_DIR=./results inspect view
```

### VS Code-Erweiterung

Mit der [Inspect AI VS Code-Erweiterung](#) können Sie Evaluationsprotokolle direkt von S3 aus durchsuchen, ohne sie zuerst herunterladen zu müssen.

1. Installieren Sie die Erweiterung vom VS Code Marketplace (suchen Sie nach „Inspect AI“)
2. Suchen Sie in der Inspect Activity Bar den Bereich Logs und wählen Sie das Ordnersymbol
3. Geben Sie Ihren S3-Pfad ein: `s3://your-bucket/eval-results/`

## Struktur der Ausgabe

Bei jeder Auswertung wird eine `.eval` Protokolldatei erstellt, die die folgenden Abschnitte enthält:

- `results.scores`— Aggregierte Ergebnisse für jede Metrik
- `samples`— Individuelle Bewertungsstichproben mit Eingaben, Ergebnissen und Ergebnissen
- `stats`— Laufzeitstatistiken einschließlich Token-Nutzung und Latenz
- `eval.config`— Die für den Testlauf verwendete Konfiguration

## Ergebnisse in MLflow anzeigen (optional)

Wenn Sie MLflow in Ihrem Rezept konfiguriert haben, generieren Sie eine vorsignierte URL für den Zugriff auf den Tracking-Server:

```
aws sagemaker create-presigned-mlflow-tracking-server-url \
 --tracking-server-name my-server \
 --region us-west-2
```

Öffnen Sie die zurückgegebene URL in Ihrem Browser, um Messwerte anzusehen, Läufe zu vergleichen und Trends in allen Bewertungen zu analysieren.

## Verfügbare Benchmarks

Der Inspect AI-Container funktioniert mit jedem Benchmark, der im Inspect AI-Aufgabenformat geschrieben wurde. Das [Inspect-Evals-Repository](#) bietet über 128 gebrauchsfertige Benchmarks aus Bereichen wie Argumentation, Wissen, Codierung und Sicherheit.

[Informationen zum Schreiben eigener Benchmarks finden Sie in der Dokumentation zum Schreiben von Inspect AI-Aufgaben.](#) Wenn Sie einen öffentlichen Benchmark finden, der noch nicht in inspect-evals verfügbar ist, können Sie die [Onboarding-Aufforderung des KI-Assistenten](#) verwenden, um ihn in das Inspect AI-Format zu konvertieren.

## Bewertungen durch Agenturen

Mit behördlichen Benchmarks wird die Fähigkeit eines Modells getestet, mehrstufige Aufgaben zu erledigen, die den Einsatz von Tools, Planung und iteratives Denken erfordern. Diese Bewertungen simulieren reale Szenarien, in denen das Modell Tools aufrufen, Ergebnisse interpretieren und über die nächsten Maßnahmen entscheiden muss.

## Anforderungen an Endgeräte

Für behördliche Evaluierungen sind Endgeräte erforderlich, die die folgenden Funktionen unterstützen:

- **Werkzeugaufruf** — Der Endpunkt muss Funktionsaufrufen unterstützen, damit das Modell während der Evaluierung Tools aufrufen kann
- **Große Kontextgröße** — Multi-turn Konversationen mit Toolergebnissen erfordern eine ausreichende Kontextlänge, um den Konversationsverlauf zu verwalten

### SageMaker Konfiguration des Inferenzendpunkts

Wenn Sie einen SageMaker Inferenzendpunkt für Agentenauswertungen verwenden, konfigurieren Sie die folgenden Umgebungsvariablen auf Ihrem Endpunkt:

| Umgebungsvariable   | Wert                       | Description                                                                                                     |
|---------------------|----------------------------|-----------------------------------------------------------------------------------------------------------------|
| ENABLE_TOOL_CALLING | True                       | Aktiviert die Unterstützung von Toolaufrufen auf dem Inferenzendpunkt                                           |
| CONTEXT_LENGTH      | Ausreichend für Multi-Turn | Stellen Sie einen Wert ein, der groß genug ist, um Multi-Turn-Konversationen mit Toolergebnissen zu ermöglichen |

Informationen zur Einrichtung von Amazon Nova-Endpunkten auf SageMaker Inference finden Sie unter [Bereitstellen von Amazon Nova-Modellen](#) auf. SageMaker Informationen zu den Funktionen und der Konfiguration von Containern finden Sie unter [Container-Funktionen](#).

### Amazon Bedrock-Endpunkte

Für Amazon Bedrock-Endpunkte wird das Aufrufen von Tools für kompatible Modelle nativ unterstützt. Weitere Informationen finden Sie unter [Verwendung von Tools mit Amazon Bedrock](#).

### Erste Schritte mit behördlichen Bewertungen

Um behördliche Bewertungen durchzuführen, müssen Sie die folgenden Voraussetzungen erfüllen:

1. Stellen Sie einen Endpunkt mit aktiviertem Tool-Calling bereit
2. Wählen Sie einen Agenten-Benchmark aus dem [Inspect-Evals-Repository](#) aus (suchen Sie nach Benchmarks, die Tool-Calling-Solver verwenden)

3. Konfiguriere dein Rezept mit geeigneten Werten für Interaktionen mit mehreren Runden `timeout` `max_tokens`

## Amazon Bedrock-Endpunkt

- Informationen zur vollständigen Einrichtung und Bereitstellung finden Sie unter [Amazon Bedrock Endpoints](#).
- Informationen zur Unterstützung beim Aufrufen von Tools finden Sie im Abschnitt zum clientseitigen Aufrufen von Tools unter [Verwendung von Tools mit Amazon Bedrock](#).

## Beispiel-Notizbücher

Das folgende Notizbuch zeigt, wie ein Agenten-Benchmark mit dem Inspect AI-Container ausgeführt wird, der Tools aufruft:

- [Tau-Bench \(auftragsbasiert\) — Evaluieren Sie mithilfe des Inspect AI-Containers das Tool-gestützte](#) Argumentationsvermögen bei Kundendienstaufgaben

Verwenden Sie für behördliche Benchmarks, die eine Docker-Sandbox erfordern, das Inspect AI SDK:

- [SWE-bench mit Inspect AI SDK](#) — Evaluieren Sie die Funktionen der Softwareentwicklung mithilfe der Docker-Sandbox

### Important

Agentische Benchmarks, für die eine Docker-Sandbox erforderlich ist (z. B. SWE-bench), werden in der Inspect AI-Container-Umgebung nicht unterstützt. Die SageMaker Training Job-Umgebung bietet keine Docker-in-Docker Funktionen. Um diese Benchmarks auszuführen, verwenden Sie das [Inspect AI SDK](#) in einer Rechenumgebung mit Docker-Zugriff (z. B. einer Amazon EC2 EC2-Instance oder einem SageMaker Notebook mit installiertem Docker).

## Fehlerbehebung

Dieser Abschnitt bietet Lösungen für häufig auftretende Probleme bei der Durchführung von Evaluierungen mit dem Inspect AI-Container.

### Tipp zur schnellen Iteration

Bevor Sie einen SageMaker Schulungsjob einreichen, testen Sie Ihre Benchmarks lokal mit dem Inspect AI SDK. Führen Sie `inspect eval my_benchmark.py` auf Ihrem lokalen Computer aus, um Aufgabendefinitionen, Abhängigkeiten und Bewertungslogik zu validieren, bevor Sie es im großen Maßstab ausführen.

### InsufficientInstanceCapacity error

Dieser Fehler tritt auf, wenn AWS die Kapazität für den angeforderten Instanztyp in Ihrer Region nicht ausreicht.

- Versuchen Sie es mit einem anderen Instance-Typ oder reichen Sie den Job in einer anderen AWS Region ein
- Verwenden Sie einen anderen Instanztyp (z. B. `m1.m5.xlarge` anstelle von `m1.m5.large`)
- Versuchen Sie die Anfrage nach ein paar Minuten erneut

### AccessDenied error

Wenn der Trainingsjob mit der Fehlermeldung „Zugriff verweigert“ fehlschlägt, überprüfen Sie Folgendes:

- Die Rolle ARN in Ihrer Jobkonfiguration ist korrekt
- Die Vertrauensrichtlinie ermöglicht `essagemaker.amazonaws.com`, die Rolle zu übernehmen
- Ihr Benutzer oder Ihre Rolle hat die `iam:PassRole` Berechtigung für die Ausführungsrolle
- Die Ausführungsrolle hat Berechtigungen für den Zugriff auf den S3-Bucket, den Inferenzendpunkt oder das Amazon Bedrock-Modell

### Die Endpunkterstellung schlägt feh

Bei der Verwendung `cleanup_endpoint: true` mit automatischer Endpunkterstellung können die folgenden Probleme auftreten:

| Fehler                                   | Lösung                                                                                                                                                                                              |
|------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| ResourceLimitExceeded                    | Beantragen Sie eine Erhöhung des Servicekontingents für den Inferenzinstanztyp in Ihrer Region                                                                                                      |
| OutOfMemoryError                         | Verwenden Sie einen größeren Inferenzinstanztyp oder reduzieren Sie die Modellgröße                                                                                                                 |
| Falsch model_s3_uri                      | Stellen Sie sicher, dass der S3-Pfad auf ein gültiges Modellartefaktverzeichnis verweist                                                                                                            |
| Falscher URI für das Inferenzbild        | Stellen Sie sicher, dass die Bild-URI für Ihre Region und Ihr Modell-Framework korrekt ist                                                                                                          |
| Der Endpunkt blieb beim Erstellen hängen | Überprüfen Sie die CloudWatch Protokolle für den Endpunkt. Das Modell kann die Integritätsprüfungen nicht bestehen. Erhöhen MaxRuntimeInSeconds Sie den Wert, wenn der Endpunkt mehr Zeit benötigt. |

## HuggingFace Timeouts beim Herunterladen

Wenn bei Benchmarks, bei denen Datensätze vom HuggingFace Hub heruntergeladen werden, eine Zeitüberschreitung eintritt, setzen Sie die HF\_HUB\_DOWNLOAD\_TIMEOUT Umgebungsvariable auf einen höheren Wert (in Sekunden):

```
--environment '{"HF_HUB_DOWNLOAD_TIMEOUT": "600"}'
```

Job wurde beendet, aber der Endpunkt läuft immer noch

Wenn der Trainingsjob unterbrochen wird, bevor die Bereinigung abgeschlossen ist, bleibt der Inferenzendpunkt möglicherweise aktiv. Löschen Sie den Endpunkt manuell, um laufende Gebühren zu vermeiden:

```
List endpoints to find the orphaned one
aws sagemaker list-endpoints \
 --name-contains inspect \
 --query "Endpoints[].EndpointName" \
 --output table
```



```
Delete the endpoint
aws sagemaker delete-endpoint \
 --endpoint-name your-endpoint-name

Delete the endpoint configuration
aws sagemaker delete-endpoint-config \
 --endpoint-config-name your-endpoint-name

Delete the model
aws sagemaker delete-model \
 --model-name your-endpoint-name
```

## Konflikte zwischen Benchmark-Abhängigkeiten

Wenn ein Benchmark aufgrund von Abhängigkeitskonflikten mit vorinstallierten Paketen fehlschlägt, erstellen Sie `pyproject.toml` im Benchmark-Verzeichnis einen mit expliziten Versionseinschränkungen. Der Container installiert Benchmark-Abhängigkeiten isoliert, um Konflikte zu minimieren.

## Die Evaluationsergebnisse sehen falsch aus

Wenn die Bewertungsergebnisse unerwartet niedrig oder inkonsistent sind, überprüfen Sie die folgenden Einstellungen in Ihrem Rezept:

- Temperatur — Auf einstellen, um deterministische, `0.0` reproduzierbare Ergebnisse zu erhalten
- `max_tokens` — Stellen Sie sicher, dass der Wert groß genug ist, damit das Modell seine Antwort abschließen kann
- `completion_mode` — Legen Sie für Basismodelle (ohne Chat) `completion_mode: true` in Ihrem Rezept fest, dass anstelle des Chat-Formats die Eingabeaufforderung im Completion-Stil verwendet wird

## Datenschutz

Ihre Bewertungsdaten werden je nach verwendetem Inferenzanbieter unterschiedlich behandelt.

## SageMaker Endpunkt

Wenn Sie einen SageMaker Inferenzendpunkt verwenden, bleiben alle Daten innerhalb Ihres AWS-Konto Bewertungsaufrufen und Modellantworten werden nicht außerhalb Ihres Kontos

gesendet und nicht zur Verbesserung AWS der Dienste verwendet. Es ist keine Opt-Out-Richtlinie erforderlich.

## Amazon Bedrock

Wenn Sie Amazon Bedrock als Inferenzanbieter verwenden, unterliegen Ihre Daten der AWS Opt-Out AI-Services-Richtlinie. Um zu verhindern, dass Ihre Daten zur Verbesserung von AWS KI-Diensten verwendet werden, aktivieren Sie die Opt-Out-Richtlinie auf AWS Organisationsebene. Weitere Informationen finden Sie unter [Richtlinien zur Deaktivierung von KI-Diensten](#).

| Anbieter von Inferenzen | Opt-out erforderlich | Details                                                                                                                                            |
|-------------------------|----------------------|----------------------------------------------------------------------------------------------------------------------------------------------------|
| SageMaker Endpunkt      | Nein                 | Daten bleiben in Ihrem Konto. Nicht durch die AI-Opt-Out-Richtlinie abgedeckt.                                                                     |
| Amazon Bedrock          | Ja                   | Aktivieren Sie die AWS Opt-Out KI-Servicerichtlinie auf Organisationsebene, um zu verhindern, dass Daten zur Serviceverbesserung verwendet werden. |

# Amazon Nova Forge

Amazon Nova Forge ist ein einzigartiger Service, der Unternehmen die einfachste und kostengünstigste Möglichkeit bietet, mithilfe von Nova ihre eigenen Grenzmodelle zu erstellen.

Amazon Nova Forge führt das Konzept der „offenen Trainingsmodelle“ ein, die Unternehmen Zugriff auf eine Vielzahl von frühen Modell-Checkpoints und die Möglichkeit bieten, in jeder Phase des Modelltrainings proprietäre Amazon-curated Daten mit Datensätzen zu kombinieren. Dadurch können die Modelle das Lernen aus firmeneigenen Daten maximieren und gleichzeitig das Risiko minimieren, grundlegende Fähigkeiten wie Argumentation zu vergessen.

Nova Forge ist in mehreren Regionen verfügbar. AWS Detaillierte Informationen zu den unterstützten Regionen finden Sie unter [Verfügbarkeit in Nova Forge-Regionen](#).

Nova Forge bietet die folgenden Hauptfunktionen:

- Greifen Sie in allen Phasen der Modellentwicklung auf Checkpoints zu und nutzen Sie neue Nova-Modelle, bevor sie allgemein verfügbar sind
- Kombinieren Sie Ihre eigenen Daten mit Nova-curated Amazon-Trainingsdaten
- Führen Sie Reinforcement-Learning mit Belohnungsfunktionen in Ihrer Umgebung durch
- Verwenden Sie Rezepte auf Knopfdruck, die für die Erstellung mit Nova über visuelle Workflows oder eine Befehlszeilenschnittstelle optimiert sind
- Verwenden Sie das Responsible AI Toolkit, um Modelle während des Trainingsprozesses an den Richtlinien für verantwortungsvolle KI von Amazon Nova auszurichten und Laufzeitkontrollen zu implementieren, um die Modellreaktionen während der Inferenz zu moderieren.

## Voraussetzungen

Themen

- [Abonnieren Sie Nova Forge](#)
- [Andere Voraussetzungen](#)

## Abonnieren Sie Nova Forge

Um Zugriff auf den Amazon Nova Forge-Service zu beantragen, fügen Sie Ihrer Konsolen-IAM-Rolle das folgende Tag hinzu: key forge-subscription mit dem Wert true. Nachdem Sie dieses Tag

zu Ihrer Rolle hinzugefügt haben, gehen Sie bitte zu SageMaker AI Console > Modelltraining und -anpassung und klicken Sie auf Nova Forge. Auf dieser Seite finden Sie Einzelheiten zum Service, Preisinformationen und Funktionen. Auf dieser Seite können Sie ein Abonnement anfordern und dann Ihr Abonnement verwalten.

1. Die Rolle sollte berechtigt sein, die API aufzurufen `ListAttachedRolePolicy`, und die Antwort sollte entweder eine `AmazonSageMakerFullAccess` Richtlinie `AdministratorAccess` oder enthalten.
2. Die Anmelderolle sollte die Erlaubnis haben, die API aufzurufen `ListRoleTags`, und die Antwort-Tags sollten Folgendes enthalten: `tag.key=forge-subscription`

## Andere Voraussetzungen

Stellen Sie außerdem sicher, dass die folgenden Voraussetzungen erfüllt sind:

1. [Allgemeine Voraussetzungen](#)
2. Zusätzliche Schritte für SageMaker HyperPod Benutzer: Fügen Sie Ihrem SageMaker HyperPod Cluster eine eingeschränkte Instanzgruppe (RIG) hinzu (um die folgenden Schritte [abzuschließen](#))

## Zugang und Einrichtung von Nova Forge

Um bei Nova Forge einzusteigen, folgen Sie diesem zweistufigen Prozess:

- Schritt 1: Abonnieren Sie Nova Forge
- Schritt 2: HyperPod Infrastruktur einrichten

## Abrufen der Nova Forge-Dokumente

Gehen Sie wie folgt vor, um die Nova Forge-Dokumente zu erhalten:

```
mkdir NovaForgeHyperpodCLI
cd NovaForgeHyperpodCLI
aws s3 cp s3://nova-forge-c7363-206080352451-us-east-1/v1/ ./ --recursive
pip install -e .
```

# Schritt 1: Abonnieren Sie Nova Forge

## Kurze Zusammenfassung:

1. Stellen Sie sicher, dass Sie Administratorzugriff auf das Amazon Web Services Services-Konto haben.
2. Navigieren Sie zur SageMaker AI-Konsole und fordern Sie Zugriff auf Nova Forge an.
3. Warten Sie, bis das Nova-Team eine Bestätigung per E-Mail sendet, nachdem Ihre Abonnementanfrage genehmigt wurde.
4. Kennzeichnen Sie Ihre SageMaker HyperPod Ausführungsrolle mit dem `forge-subscription` Tag. Dieses Tag ist erforderlich, um auf die Funktionen und Checkpoints von Nova Forge zuzugreifen. Fügen Sie Ihrer Ausführungsrolle das folgende Tag hinzu:
  - Schlüssel: `forge-subscription`
  - Wert: `true`

## Ausführlicher Leitfadens

Um Nova Forge zu abonnieren und den Anpassungsservice effektiv zu nutzen, muss ein Kunde von Amazon Web Services über Administratorzugriff auf sein Amazon Web Services Services-Konto verfügen oder sich von seinem Administrator Administratorzugriff gewähren lassen. In diesem Dokument werden die Schritte beschrieben, die erforderlich sind, um:

- Sicherer Administratorzugriff
- Richten Sie Richtlinien ein, um Nova Forge zu abonnieren
- Greife auf Anpassungsrezepte zu
- Passen Sie die Anpassung an
- Überwachen Sie den Arbeitsablauf
- Evaluieren Sie den Checkpoint für das benutzerdefinierte Modell

## Option A

Ablauf 1: Der Kontonutzer muss sich an den Kontoadministrator wenden, um Folgendes anzufordern:

- Fügen Sie das `forge-subscription` Tag über IAM zum Konto hinzu (die Schritte finden Sie in Anhang A).

- Fügen Sie die `ListRoleTags` und `ListAttachedRolePolicies` -Berechtigungen über IAM hinzu (die Schritte finden Sie in Anhang B).

*Required setup for requesting subscription*  
 To request Nova Forge subscription, your IAM role must have the "forge-subscription" tag attached and the "ListRoleTags" and "ListAttachedRolePolicies" policies added.
 [Learn more ↗](#)

### Nova Forge

Choose from multiple Nova model checkpoints to introduce your data at the optimal stage, mix Amazon-curated training data from each stage with your data, integrate your proprietary tools as reward functions, customize the responsible AI controls, and build your own custom frontier model.

[Request subscription](#) [Documentation ↗](#)

#### Subscription

Request subscription to access Nova Forge resources. Once approved, your payer account will be eligible for a 1-month free trial. **Infrastructure costs will apply during the free trial.** See Nova Forge pricing details below.

**Status**

☐ Not subscribed

## Option B

Ablauf: Der Kontonutzer muss sich an den Kontoadministrator wenden, um Administratorzugriff auf das Konto zu beantragen.


- Sobald der Administratorzugriff gewährt wurde, befolge die Schritte in Flow 2.

## Flow 2. Amazon Web Services Services-Konto mit Administratorzugriff


- Fügen Sie dem Konto über IAM das Forge-Abonnement-Tag hinzu. Die Schritte finden Sie in Anhang A

## Anhang A. Forge-Abonnement-Richtlinie zum Amazon Web Services Services-Konto hinzufügen


1. Gehen Sie zum Amazon Web Services IAM-Dashboard. Klicken Sie links auf Rollen. Suchen Sie nach Admin und klicken Sie auf die Admin-Rolle




2. Wählen Sie < AssumedRoleToUse > (z. B. libsAdminAccess). Klicken Sie auf den Tab Tags.



3. Klicken Sie auf Tabs verwalten. Neues Tag hinzufügen. Geben Sie unter Schlüssel „forge-subscription“ ein und klicken Sie auf Änderungen speichern




4. Stellen Sie sicher, dass Sie Forge-Subscription als Schlüssel im Abschnitt „Tags“ sehen






## Anhang B. Hinzufügen ListRoleTags von ListAttachedPolicies Richtlinien zum Amazon Web Services Services-Konto für Non-Admin Rolle nach Administrator

1. Gehen Sie zum Amazon Web Services IAM-Dashboard. Klicken Sie links auf Rollen. Suchen Sie nach < AssumedRoleToUse > (z. B. ForgeAccessRole) und klicken Sie auf die Rolle < AssumedRoleToUse > (z. B. ForgeAccessRole)




2. Klicken Sie auf die Rolle < AssumedRoleToUse > (z. B. ForgeAccessRole) und wählen Sie Tags aus. Füge ein neues Tag mit dem Typ „forge-subscription“ hinzu



3. Fügen Sie unter Berechtigungen eine neue Berechtigung hinzu: Berechtigungen hinzufügen → Inline-Richtlinie erstellen → Fügen Sie die folgende unten aufgeführte Richtlinie hinzu

```
{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Sid": "VisualEditor0",
 "Effect": "Allow",
 "Action": [
 "iam:ListRoleTags",
 "iam:ListAttachedRolePolicies"
],
 "Resource": "*"
 }
]
}
```



## Schritt 2. HyperPod Infrastruktur einrichten

Richten Sie die erforderliche SageMaker HyperPod Infrastruktur ein, indem Sie die [Workshop-Anweisungen](#) zur Konfiguration der Umgebung mit Forge-enabled Funktionen befolgen.

## Einstellungen für die Inhaltsmoderation

Wenn Sie Zugriff auf Nova Forge benötigen, sind anpassbare Inhaltsmoderationseinstellungen (CCMS) für die Modelle Amazon Nova Lite 1.0 und Pro 1.0 verfügbar. CCMS ermöglicht die Anpassung der Kontrollen für die Inhaltsmoderation an spezifische Geschäftsanforderungen und gewährleistet gleichzeitig grundlegende verantwortungsvolle KI-Schutzmaßnahmen. Um festzustellen, ob ein Geschäftsmodell für CCMS geeignet ist, wenden Sie sich an einen Account Manager. AWS

Weitere Informationen zur Konfiguration und Verwendung von CCMS mit benutzerdefinierten Modellen finden Sie im Abschnitt [Responsible AI Toolkit und Inhaltsmoderation](#).

## Fortsetzung und Pre-Training Mid-Training

### Note

Eine ausführliche Dokumentation wird nach dem Abonnieren zur Verfügung gestellt

Nova Forge CPT bietet erweiterte Funktionen, die über das Standard-CPT hinausgehen, darunter den Zugriff auf zwischengeschaltete Checkpoints und die Datenmischung mit dem Nova-Vortrainingskorpus. Diese Funktionen ermöglichen eine effizientere Domänenanpassung und eine bessere Erhaltung der allgemeinen Fähigkeiten des Modells.

## Was sind Zwischenkontrollpunkte und warum werden sie benötigt?

Zwischenprüfpunkte sind Schnappschüsse des Amazon Nova-Modells, die in verschiedenen Phasen der Vorschulung gespeichert wurden, bevor das Modell seinen endgültigen produktionsreifen Zustand erreicht. Während der Modellentwicklung durchläuft Amazon Nova mehrere Schulungsphasen: anfängliches Vortraining mit konstanter Lernrate, Erhöhung der Lernrate, Schulung zur Kontexterweiterung und schließlich Schulung zur Ausrichtung und Sicherheit nach Anweisungen. Bei CPT sind zwischengeschaltete Checkpoints oft dem finalen Prod-Checkpoint vorzuziehen, da sie plastischer und empfänglicher für Domainanpassungen sind. Der Prod-Checkpoint wurde einem umfassenden Angleichungs- und Sicherheitstraining unterzogen, bei dem die Anweisungen befolgt wurden. Dadurch wurde das Modell zwar für den allgemeinen Gebrauch in Konversationen optimiert, es ist jedoch möglicherweise resistent gegen das Erlernen neuer domänenspezifischer Muster während der CPT. Im Gegensatz dazu behalten Checkpoints, die nur teilweise oder vollständig vortrainierten Text enthalten, die Merkmale des Modells vor dem Training bei. Sie wurden nicht stark auf bestimmte Verhaltensweisen ausgerichtet, was sie zu effizienteren Ausgangspunkten für die Domänenanpassung macht. Bei der Durchführung umfangreicher CPT (>10B-Token) führt der Start von zwischengeschalteten Checkpoints in der Regel zu einer schnelleren Konvergenz, einer besseren Trainingsstabilität und einem effektiveren Erwerb von Fachwissen. Für CPT in kleinem Maßstab (<10 B-Token) oder wenn die Fähigkeit zur Befolgung von Anweisungen beibehalten werden muss, ist der Prod-Checkpoint jedoch möglicherweise besser geeignet, da er eine Domänenanpassung ermöglicht und gleichzeitig die Konversationsfähigkeit des Modells beibehält.

Für CPT sind mehrere Zwischenprüfpunkte erforderlich, da sie unterschiedliche Ebenen der Modellplastizität bieten, die beeinflussen, wie effizient das Modell neues Domänenwissen aufnehmen kann. Der letzte Prod-Checkpoint wurde einem umfassenden Angleichungs- und Sicherheitstraining unterzogen. Dadurch wurde er für allgemeine Konversationszwecke optimiert, ist aber resistent gegen das Erlernen neuer domänenspezifischer Muster. Mit anderen Worten, er wurde nach dem Training noch weiter verschärft. Im Gegensatz dazu haben frühere Checkpoints die Merkmale des Modells vor dem Training beibehalten und waren nicht stark auf bestimmte Verhaltensweisen ausgerichtet, wodurch sie plastischer und empfänglicher für Domänenanpassungen wurden.

Um die beste Trainingseffizienz zu erreichen, sind mehrere Zwischenkontrollpunkte vorgesehen.

## Welche Checkpoints sind verfügbar?

### Nova 2.0

Es gibt drei Amazon Nova Lite 2.0-Checkpoints.

- **PRE-TRAINED** - [nova-lite-2/pretraining-text-RD]: Dies ist der Checkpoint nach der konstanten Lernrate und den Ramp-Down-Phasen der Amazon Nova-Vorschulung, bei der das Modell mit Billionen von Tokens trainiert wird.
- **MID-TRAINED** - [nova-lite-2/pretraining-text-CE]: Dieser Checkpoint ermöglicht die Einführung von Zwischenmengen unstrukturierter Daten mit einer konservativeren Lernrate als vor dem Training, wodurch domänenspezifisches Wissen aufgenommen und gleichzeitig katastrophales Vergessen vermieden wird.
- **POST-TRAINED** - [nova-lite-2/prod]: Dies ist der vollständig abgestimmte letzte Kontrollpunkt des Modells, das alle damit verbundenen Schritte und die nach dem Training durchzuführenden Schritte durchlaufen hat.

In der folgenden Tabelle werden die verschiedenen Bedingungen für die Dauer des Trainings vor und während des Trainings näher erläutert.

| Datentyp                                                                                | Durchführen              | Mit Checkpoint |
|-----------------------------------------------------------------------------------------|--------------------------|----------------|
| Large-scale unstrukturierte Domain-Rohdaten (Dokumente, Protokolle, Artikel, Code usw.) | Fortsetzung Pre-Training | Pre-Trained    |

| Datentyp                                                                                                           | Durchführen                       | Mit Checkpoint |
|--------------------------------------------------------------------------------------------------------------------|-----------------------------------|----------------|
| Large-scale unstrukturierte Domain-Rohdaten (Dokumente, Protokolle, Artikel, Code usw.)                            | Mid-Training                      | Pre-Trained    |
| Kleinere Mengen unstrukturierter Rohdaten. Spuren strukturierter Argumentationen/CoT-Daten                         | Mid-Training                      | Mid-Trained    |
| Strukturierte Demonstrationen (hochwertige Input-Output-Paare, kuratierte Aufgabenanweisungen, Multi-Turn-Dialoge) | Vollständig Fine-Tuning           | Mid-Trained    |
| Strukturierte Demonstrationen (hochwertige Input-Output-Paare, kuratierte Aufgabenanweisungen, Multi-Turn-Dialoge) | Effizienter Parameter Fine-Tuning | Post-Trained   |

## Welcher Checkpoint soll verwendet werden?

Checkpoints mit nur teilweise vortrainiertem Text und vollständig vortrainiertem Nur-Text-Checkpoint laufen in der Regel schneller zusammen und erfordern weniger Trainingsschritte für die Domänenanpassung. Sie verfügen jedoch nicht über eine Anpassung der Anweisungen und müssten nach dem Training weitere Schritte durchlaufen, um nützliche Aufgaben ausführen und Anweisungen befolgen zu können. Der GA-Checkpoint erfordert möglicherweise mehr Anpassungsschritte, bietet jedoch einen sichereren Ausgangspunkt für Experimente in kleinem Maßstab und bietet auch nach der CPT-Schulung einige seiner Funktionen nach dem Training.

Im Allgemeinen sollten Sie bei großen Trainingsdatensätzen (>10B-Token) mit Checkpoints beginnen, die nur teilweise oder nur vollständig vortrainierten Text enthalten, um ein effizienteres und stabileres Training zu erreichen, da die Wissensbasis des Modells erheblich verändert wird.

Verwenden Sie bei kleinen Datensätzen (<10 B-Tokens) den GA-Checkpoint, um die Funktionen zur Befolgung von Anweisungen beizubehalten und sich gleichzeitig an die Domäne anzupassen.

## Wie verwendet man das Mischen von Daten für Nova 2.0?

Bei der Durchführung von CPT mit neuen Domänendaten ist es äußerst vorteilhaft, die neuen Daten mit einigen der Daten zu kombinieren, die zuvor in der Vortrainingsphase des Modells verwendet wurden. Durch das Mischen alter Daten mit neuen Domänendaten werden zwei Probleme gelöst:

- **Kontrolle vergessen:** Verhindert katastrophales Vergessen, indem vorhandene Fähigkeiten und Kenntnisse über das Modell erhalten bleiben. Ohne Datenmischung führt ein Training ausschließlich mit eng begrenzten Domänendaten dazu, dass das Modell allgemeine Funktionen überschreibt. Beispielsweise kann ein Modell, das nur anhand von Rechtsdokumenten trainiert wurde, seine Fähigkeit zum Programmieren oder Rechnen verlieren. Durch das Mischen der Datensätze für allgemeine Bereiche bleiben diese allgemeinen Fähigkeiten erhalten, während gleichzeitig das neue Fachgebiet erworben wird.
- **Optimierungsstabilität:** Die Stabilität des Trainings wird aufrechterhalten, indem die internen Repräsentationen des Modells verankert werden. Während der CPT werden die erlernten Merkmale des Modells modifiziert, und die Datenmischung sorgt für Gradienten aus verschiedenen Quellen, die für eine reibungslose Anpassung sorgen. Ohne sie kann das Training mit engen Verteilungen zu Instabilität der Gradienten führen, sodass sich die Repräsentationen des Modells zu drastisch verschieben, was zu Trainingsdivergenz, Verlustspitzen oder zum Zusammenbruch vorhandener Fähigkeiten führt. Das ist der Kompromiss zwischen Stabilität und Plastizität: Das Modell sollte plastisch genug sein, um neues Fachwissen zu erlernen, aber stabil genug, um das, was es bereits weiß, nicht kaputt zu machen.

### Funktionen zum Mischen von Daten in Nova CPT

Der Zugriff auf Amazon Nova-Daten und Checkpoints vor dem Training ist eines der Kernangebote der Amazon Nova CPT-Anpassung. Die CPT-Anpassung von Amazon Nova ermöglicht das einfache Mischen von Domaindaten mit dem Vortrainingskorpus von Amazon Nova. Darüber hinaus kann das Stichprobenverhältnis der spezifischen Amazon Nova-Datenkategorien (z. B. Code, Mathematik, Argumentation usw.) geändert und ihre Proportionen so gesteuert werden, dass sie die Domaindaten ergänzen. Dies ermöglicht die Stärkung der Funktionen, die auf den Anwendungsfall abgestimmt sind, und gleichzeitig das Modell an die spezifische Domäne anzupassen.

### Finden des optimalen Mischungsverhältnisses

Das optimale Verhältnis von Amazon Nova-Daten zu Domaindaten hängt von der Domäne, Komplexität, Größe, Qualität und der Bedeutung der Aufrechterhaltung allgemeiner Funktionen des Datensatzes ab. Dieses Verhältnis muss durch Experimente herausgefunden werden. Ein Versuchsrahmen, um zu entscheiden, wie viele Amazon Nova-Daten gemischt werden sollen, sieht wie folgt aus.

Wählen Sie eine repräsentative Teilmenge von Domänendaten (z. B. 5B-Token) aus und halten Sie diese bei allen Versuchsläufen konstant.

Führen Sie kleine CPT-Experimente durch, bei denen nur die Menge der eingemischten Amazon Nova-Daten variiert wird:

- Keine Vermischung: 100% Domäne → Nur 5B-Domäne (insgesamt 5B)
- Lichtmischung: 90% Domäne → 5B-Domäne + ~0,56 B Amazon Nova (insgesamt ~5,56 B)
- Mittlere Mischung: 70% Domäne → 5B-Domäne + ~2,14 B Amazon Nova (insgesamt ~7,14 B)
- Starke Mischung: 50% Domäne → 5B-Domäne + 5B Amazon Nova (insgesamt 10B)

Bewerten Sie jeden Checkpoint anhand von Domain-Benchmarks und allgemeinen Domain-Benchmarks. Evaluieren Sie auch den Startkontrollpunkt (Amazon Nova-Checkpoint vor jedem Training).

- Bleibt die Leistung der Kundendomäne bei allen Durchläufen ungefähr konstant? In der Regel sollte dies der Fall sein, da bei jedem Lauf dieselbe Anzahl von Domain-Tokens verwendet wurde. Wenn sich die Domain-Performance bei stärkerer Vermischung verbessert, bieten Amazon Nova-Daten eine nützliche Regularisierung.
- Verbessern sich die allgemeinen Benchmark-Werte, wenn die Mischung zunimmt?
  - Das erwartete Verhalten ist, dass sich die allgemeinen Funktionen monoton verbessern sollten, wenn mehr Amazon Nova-Daten hinzugefügt werden.
  - Messen Sie mehrere allgemeine Benchmarks: MMLU (Allgemeinwissen), HumanEval (Kodierung), GSM8K (Mathematik) oder spezifische Benchmarks von Interesse.
- Wählen Sie das Mischungsverhältnis, das die Domänenleistung beibehält und gleichzeitig akzeptable allgemeine Funktionen für die jeweiligen Anwendungsfälle bietet. Berücksichtigen Sie die zusätzlichen Kosten für Schulungen, wenn mehr Daten gemischt werden.

Sobald das optimale Mischungsverhältnis ermittelt wurde, führen Sie CPT in voller Größe aus und verwenden dabei den vollständigen Domänendatensatz mit dem ausgewählten Mischungsverhältnis.



## Analyse der Datenmischungskategorien

Im Folgenden analysieren wir jede verfügbare Kategorie in Data Mixing, damit Sie am besten entscheiden können, welche Datenkategorien in Ihrer gesamten Datenmischung am sinnvollsten dargestellt werden sollen.

### Wie aktiviert man das Mischen von Daten

Fügen Sie Ihrem Rezept den `data_mixing` Abschnitt mit der entsprechenden prozentualen Verteilung auf die Datensatzkategorien hinzu. Die Summe der `nova_data` Prozentsätze muss 100 ergeben.

### Nova 2.0-Konfiguration mit Datenmischung

```
Note:
This recipe can run on p5.48xlarge

Run config
display_name: "Nova Lite Pretrain on P5 GPU"
versions: ["2.0"]
instance_types: ["ml.p5.48xlarge"]

run:
 name: "my-cpt-run" # A descriptive name for your training job
 model_type: "amazon.nova-2-lite-v1:0:256k" # Model variant specification, do not
change
 model_name_or_path: "nova-lite-2/prod" # Base model path, do not change
 replicas: 8 # Number of compute instances for training, allowed values are 4,
8, 16, 32
 data_s3_path: "" # Customer data paths
 validation_data_s3_path: "" # Customer validation data paths
 output_s3_path: "" # Output artifact path, SageMaker HyperPod job-specific
configuration - not compatible with standard SageMaker Training jobs

Training specific configs
training_config:
 task_type: cpt
 max_length: 8192 # Maximum context window size (tokens)
 global_batch_size: 64 # Global batch size, allowed values are 32, 64, 128,
256.

 trainer:
```

```

max_steps: 10 # The number of training steps to run total
val_check_interval: 10 # The number of steps between running validation
limit_val_batches: 2 # Batches of the validation set to use each trigger

model:
 hidden_dropout: 0.0 # Dropout for hidden states, must be between 0.0 and
1.0
 attention_dropout: 0.0 # Dropout for attention weights, must be between 0.0
and 1.0

optim:
 optimizer: adam
 lr: 1e-5 # Learning rate
 name: distributed_fused_adam # Optimizer algorithm, do not change
 adam_w_mode: true # Enable AdamW mode
 eps: 1e-06 # Epsilon for numerical stability
 weight_decay: 0.0 # L2 regularization strength, must be between 0.0 and
1.0
 adam_beta1: 0.9 # Beta1 for Adam optimizer
 adam_beta2: 0.95 # Beta2 for Adam optimizer
 sched:
 warmup_steps: 10 # Learning rate warmup steps
 constant_steps: 0 # Steps at constant learning rate
 min_lr: 1e-6 # Minimum learning rate, must be lower than lr

data_mixing:
 dataset_catalog: cpt_text_lite
 sources:
 nova_data: # percent inputs for Nova data must sum to 100%; use 0% if you want to
exclude a data grouping
 agents: 20
 business-and-finance: 4
 scientific: 10
 code: 5
 factual-and-news: 5
 longform-text: 6
 health-and-medicine: 1
 humanities-and-education: 1
 legal: 1
 math: 9
 additional-languages: 15
 social-and-personal-interest: 11
 entertainment: 0.5
 reasoning: 10

```

```

other: 0.5
tables: 1
customer_data: # percent input of customer data. 100 = use only customer data, 0 =
use only the nova_data mix above
percent: 25

```

## Was bedeuten diese Kategorien

Hinweis: Nova 2.0 enthält zusätzliche Kategorien, die für das Denken spezifisch sind (z. B. `reasoning-code`, `reasoning-math`, `reasoning-instruction-following`), die in Nova 1.0 nicht verfügbar sind.

Zusammenfassung der Kategorien und Informationsbeschriftungen:

| Name der Kategorie | Einzelheiten der Informationen                                                                                                                                |
|--------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------|
| agents             | Die Trainingsdaten konzentrierten sich auf autonome Entscheidungsfindung, Aufgabenerfüllung und zielorientiertes Verhalten in KI-Systemen                     |
| baseline           | Die grundlegenden Sprachdaten konzentrierten sich auf das allgemeine Verständnis, die grundlegende Kommunikation und die wichtigsten sprachlichen Fähigkeiten |
| chat               | Konversationsaustausch, der einen natürlichen Dialogfluss, die Aufrechterhaltung des Kontextes und angemessene soziale Interaktionen demonstriert             |
| code               | Programmierquellcode, Dokumentation und technische Diskussionen aus verschiedenen Programmiersprachen und Plattformen.                                        |
| factuality         | Referenzmaterialien und verifizierte Informationen mit Schwerpunkt auf Genauigkeit, Quellvalidierung und Wahrheitsbeurteilung                                 |
| identity           | Persönlichkeitsrahmen und Verhaltensmuster konzentrierten sich auf konsistente Charaktereigenschaften, Werte und Interaktionsstile                            |
| long-context       | Ausführliche Texte und komplexe Erzählungen konzentrierten sich auf die Wahrung von Kohärenz und Relevanz bei längeren Austauschen                            |

| Name der Kategorie              | Einzelheiten der Informationen                                                                                                                         |
|---------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------|
| math                            | Mathematische Inhalte, darunter Lehrbücher, Probleme, Lösungen und mathematische Diskussionen.                                                         |
| rai                             | Fälle und Szenarien, in denen ethische KI-Prinzipien, Sicherheitsüberlegungen und verantwortungsvoller Technologieeinsatz im Vordergrund stehen        |
| instruction-following           | Beispiele für die präzise Ausführung von Aufgaben auf der Grundlage unterschiedlicher Ebenen von Benutzeraufforderungen und -anweisungen               |
| stem                            | Technische Inhalte aus den Bereichen Wissenschaft, Technologie, Ingenieurwesen und Mathematik, einschließlich Problemlösung und theoretischer Konzepte |
| planning                        | Sequenzen, die strategisches Denken, schrittweise Aufschlüsselung von Aufgaben und effiziente Ressourcenzuweisung demonstrieren                        |
| reasoning-chat                  | Analytische Dialogszenarien konzentrierten sich auf logische Diskussionen und strukturierte Gesprächsabläufe                                           |
| reasoning-code                  | Herausforderungen bei der Programmierung und algorithmische Probleme standen im Mittelpunkt der systematischen Lösungsentwicklung                      |
| reasoning-factuality            | Die Szenarien zur Informationsbewertung konzentrierten sich auf kritische Bewertungs- und Überprüfungsprozesse                                         |
| reasoning-instruction-following | Komplexe Aufgabenanalyse mit Schwerpunkt auf systematischer Interpretation und methodischer Ausführung                                                 |
| reasoning-math                  | Mathematische Problemlösungsszenarien mit Schwerpunkt auf logischer Weiterentwicklung und Lösungsstrategien                                            |
| reasoning-planning              | Strategische Entscheidungsszenarien konzentrierten sich auf einen systematischen Ansatz zur Zielerreichung                                             |

| Name der Kategorie | Einzelheiten der Informationen                                                                                                                               |
|--------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------|
| reasoning-rag      | Szenarien zur Informationsgewinnung und -synthese konzentrierten sich auf das kontextuelle Verständnis und die entsprechende Anwendung                       |
| reasoning-rai      | Ethische Entscheidungsszenarien konzentrierten sich auf die systematische Bewertung der Sicherheit und Fairness von KI                                       |
| reasoning-stem     | Wissenschaftliche Problemlösungsszenarien mit Schwerpunkt auf methodischer Analyse und Lösungsentwicklung                                                    |
| rag                | Beispiele für die effektive Kombination von abgerufenem externem Wissen mit generierten Antworten zur Bereitstellung genauer, kontextbezogener Informationen |
| translation        | Multi-language Inhaltspaare, die eine genaue Übersetzung unter Beibehaltung von Kontext, Tonalität und kulturellen Nuancen zeigen                            |

### Leitfaden für Parameter

- `dataset_catalog`: Wird verwendet `cpt_text_lite`, um kuratierte Daten aus FSx zu lesen (Standard) oder `cpt_text_lite_s3` um kuratierte Daten aus Amazon S3 zu streamen und die Speicherkosten zu reduzieren. Weitere Informationen finden Sie unter [the section called “Senken Sie die Speicherkosten, indem Sie Trainingsdaten von Amazon S3 streamen”](#).
- `nova_data`: Prozentsatz der einzelnen Kategorien von Nova-Daten, wenn sie miteinander vermischt wurden. Sie sollten zusammen 1,0 ergeben.
- `customer_data`: Der Prozentsatz der Kundendaten, die mit den Nova-Daten vermischt wurden.

Die Gesamtzahl der im Training verwendeten Token kann anhand von `max_length` `global_batch_size` `max_steps` berechnet werden

## Senken Sie die Speicherkosten, indem Sie Trainingsdaten von Amazon S3 streamen

Wenn Sie Continued Pre-Training (CPT) -Jobs ausführen, liest Nova Forge standardmäßig von Amazon kuratierte Trainingsdaten aus einem FSx for Lustre-Dateisystem. Das gesamte kuratierte

Korpus ist umfangreich, und wenn Sie es auf FSx speichern, erhöhen sich Ihre Speicherkosten für Schulungen.

Sie können sich für ein alternatives Datenlayout entscheiden, das die kuratierten Trainingsdaten während des Trainings von Amazon S3 streamt. Ihr FSx-Dateisystem wird weiterhin für Ihre eigenen Datensätze, Checkpoints und Jobausgaben verwendet, aber die kuratierten Trainingsdaten werden bei Bedarf direkt aus S3 gelesen. Dadurch wird der kuratierte Datensatz aus Ihrem FSx-Speicherbedarf entfernt und die Speicherkosten von CPT-Jobs können erheblich gesenkt werden, insbesondere bei Trainingsläufen mit langer Laufzeit.

Die kuratierten Daten, die Mischungsverhältnisse und die Zusammensetzung der Datensätze sind identisch mit dem Standardkatalog. Nur der Quellspeicherort ändert sich.

## Voraussetzungen

- Ihr Trainings-RIG muss am oder nach dem 1. März 2026 erstellt werden. RIGs, die vor diesem Datum erstellt wurden, enthalten nicht die Komponenten, die zum Streamen der kuratierten Trainingsdaten aus S3 erforderlich sind. Wenn Ihr RIG älter ist, erstellen Sie es neu, um diese Funktion nutzen zu können.
- Die Funktion gilt derzeit für den Textkatalog, der mit Amazon Nova Lite verwendet wird. Andere Kataloge sind nicht berechtigt.

## Aktiviere S3-backed Trainingsdaten in deinem Rezept

Wechseln Sie im `data_mixing` Abschnitt Ihres CPT-Rezepts `dataset_catalog` zu `cpt_text_lite_s3`. Alles andere in deinem Rezept bleibt gleich.

```
run:
 name: my-cpt-run
 model_type: amazon.nova-2-lite-v1:0:256k
 model_name_or_path: nova-lite-2/prod
 replicas: 4
 data_s3_path: s3://my-bucket/my-dataset
 output_s3_path: s3://my-bucket/my-output

training_config:
 task_type: cpt
 max_length: 8192
 global_batch_size: 32
```

```
save_steps: 1000
trainer:
 max_steps: 5000
optim:
 lr: 1.0e-05

data_mixing:
 dataset_catalog: cpt_text_lite_s3 # stream curated data from S3
 sources:
 customer_data:
 percent: 25
```

Senden Sie den Job mit demselben Workflow wie jedes andere CPT-Rezept. Nova Forge übernimmt das S3-Datenstreaming während der Trainingseinrichtung ohne zusätzliche Konfiguration Ihrerseits.

## Was ist zu erwarten

- Die ersten Minuten jedes Jobs beinhalten eine kurze Phase der Datenvorbereitung, während Nova Forge das Datenlayout für Ihre Region festlegt. Diese Phase ist einmalig pro Job.
- Der Durchsatz der Trainingsschritte ist mit dem FSx-backed Standardkatalog vergleichbar. Das Laden von Daten erfolgt parallel zum Training, sodass S3-Streaming beim Steady-State-Training nicht zum Engpass wird.
- Ihre eigenen Trainingsdaten (der Datensatz, den Sie bereitstellendata\_s3\_path) werden weiterhin auf FSx bereitgestellt und sind von dieser Einstellung nicht betroffen.

## Einschränkungen

- Die Funktion ist nur für den Textkatalog auf Amazon Nova Lite verfügbar. Die Verwendung cpt\_text\_lite\_s3 mit anderen Modellen oder Aufgabentypen führt bei der Auftragsübermittlung zu einem Fehler mit einem ungültigen Katalog.
- Änderungen während dataset\_catalog der Ausführung werden nicht unterstützt. Stellen Sie es bei der Einreichung des Jobs ein.

## Zum Standardkatalog zurückkehren

Wenn Sie jederzeit zum FSx-resident Standardkatalog zurückkehren möchten, legen Sie dies dataset\_catalog: cpt\_text\_lite in Ihrem Rezept fest. Es sind keine weiteren Änderungen erforderlich.

## Einschränkungen

Das aktuelle CPT unterstützt nur Textdaten und keine multimodalen Kundendatensätze.

## Betreut Fine-Tuning

Die Datenmischung von Amazon Nova Forge ermöglicht es Ihnen, Ihre benutzerdefinierten Trainingsdaten während der überwachten Feinabstimmung (SFT) mit den firmeneigenen Trainingsdaten von Amazon Nova zu kombinieren. Dies trägt dazu bei, die allgemeinen Funktionen des Modells beizubehalten und es gleichzeitig auf Ihre Zieldomäne zu spezialisieren. Das Mischen von Daten ist auf zwei Plattformen verfügbar:

- SageMaker HyperPod— Verwenden Sie YAML-Rezeptdateien, um das Mischen von Daten sowohl mit Text- als auch mit multimodalen Daten zu konfigurieren. Unterstützt LoRa und Full-Rank-SFT.
- SageMaker Trainingsjobs — Verwenden Sie die serverlose `CreateTrainingJob` API `ServerlessJobConfig` für reine Text-SFT mit Datenmischung. Unterstützt LoRa und Full-Rank.

### Themen

- [Datenmischung an SageMaker HyperPod](#)
- [Datenmischung bei SageMaker Trainingsjobs](#)

## Datenmischung an SageMaker HyperPod

### Einführung

Supervised Fine-Tuning (SFT) ist ein Trainingsansatz, bei dem Datensätze verwendet werden, die Input-Output-Paare enthalten. Sie geben Beispiele für Eingabeaufforderungen zusammen mit den richtigen Antworten an, und das Modell lernt, ähnliche Ergebnisse zu erzielen. Die Gewichtungen des Modells werden so angepasst, dass ein überwachter Verlust, typischerweise eine Kreuzentropie zwischen den Vorhersagen und den Ziel-Antwort-Tokens, minimiert wird.

### Wann sollte die überwachte Feinabstimmung eingesetzt werden

SFT eignet sich am besten, wenn Sie eine klar definierte Aufgabe mit klar definierten Ergebnissen haben. Wenn Sie explizit sagen können: „Bei gegebener X-Eingabe ist die correct/desired Ausgabe Y“ und Sie können Beispiele für solche X-Y Zuordnungen sammeln, dann ist die überwachte



Feinabstimmung eine gute Wahl. Zu den Szenarien, in denen SFT hervorragende Leistungen erbringt, gehören:

- Strukturierte oder komplexe Klassifizierungsaufgaben — Zum Beispiel die Klassifizierung interner Dokumente oder Verträge in viele benutzerdefinierte Kategorien. Mit SFT kann das Modell diese spezifischen Kategorien viel besser lernen, als wenn es nur Eingabeaufforderungen erfordert.
- Question-answering oder Transformationsaufgaben mit bekannten Antworten — zum Beispiel die Feinabstimmung eines Modells zur Beantwortung von Fragen aus der Wissensdatenbank eines Unternehmens oder zur Konvertierung von Daten zwischen Formaten, wobei jede Eingabe eine korrekte Antwort hat.
- Einheitlichkeit bei Formatierung und Stil: Wenn Sie möchten, dass das Modell immer in einem bestimmten Format oder Ton reagiert, können Sie anhand von Beispielen für die richtigen Antworten Feinabstimmungen vornehmen. `format/tone` Wenn Sie beispielsweise anhand von Paaren zwischen Aufforderung und Antwort trainieren, die eine bestimmte Markensprache oder einen bestimmten Stil vermitteln, können Sie dem Modell beibringen, diesen Stil in seinen Ergebnissen zu berücksichtigen. Instruction-following Verhalten wird häufig zunächst über SFT anhand von kuratierten Beispielen für gutes Assistenzverhalten vermittelt.

SFT ist der direkteste Weg, einem LLM eine neue Fähigkeit oder ein neues Verhalten beizubringen, wenn Sie angeben können, wie das richtige Verhalten aussieht. Es nutzt das bestehende Sprachverständnis des Modells und konzentriert es auf Ihre Aufgabe. Verwenden Sie SFT nicht, wenn die Lücke eher im Wissen als im Verhalten besteht. Dadurch lernt das Modell nicht neue Fakten, Fachjargon oder aktuelle Ereignisse. In diesen Fällen sollten Sie lieber fortlaufende Vorschulungen an großen Korpora innerhalb eines Fachgebiets oder eine generierte Generierung durchführen, um externes Wissen als Inferenz heranzuziehen. Wenn Sie die Qualität messen können, aber keine einzige Antwort als richtig bezeichnen können, ist eine verstärkte Feinabstimmung mit nachweisbaren Prämien oder an möglicherweise der SFT vorzuziehen. LLM-as-judge

Planen Sie je nach Aufgabenkomplexität und Leistung des Nova-Modells ohne Feinabstimmung Tausende bis Zehntausende von Demonstrationen pro Aufgabe ein, wobei Datenqualität, Konsistenz und Vielfalt wichtiger sind als das reine Volumen.

Sie haben die Wahl zwischen parametereffizienter und vollwertiger SFT

Mit den Anpassungsrezepten von Nova können Sie parametereffizient, insbesondere LoRa oder Full-Rank-SFT, ausführen. Wenn Sie eine einfache, kosteneffiziente Modellaktualisierung wünschen oder

nur über sehr wenige Daten verfügen, bevorzugen Sie parametereffiziente Methoden, sodass Sie kleine Adapter trainieren und gleichzeitig den größten Teil des Backbones unberührt lassen (SFT mit vollem Rang aktualisiert alle Modellparameter).

## Datenmischung für SFT

Mit der Datenmischung können Sie Ihre benutzerdefinierten Trainingsdatensätze mit den firmeneigenen Trainingsdaten von Nova kombinieren. Diese Funktion ist sowohl für Nova 1.0- als auch für Nova 2.0-Modelle verfügbar.

Proprietärer Nova-Datentyp: Nova unterstützt sowohl Text- als auch multimodale SFT-Datentypen. Es ist in mehrere Datenkategorien unterteilt, die jeweils eine Mischung von Aufgaben enthalten, die für die entsprechende Kategorie relevant sind.

Proprietäre Datenkategorien von Nova: Textdatensätze umfassen mehrere Kategorien, darunter: autonome Entscheidungsfindung, Aufgabenerfüllung, zielorientierte Datensätze (Agenten), sowohl mit Argumentation als auch ohne Argumentation präzise Datensätze zur Ausführung von Aufgaben (Argumentation-Instruction-Following, Instruction-Following), Sequenzen, die strategisches Denken und schrittweise Aufschlüsselung von Aufgaben (Planung) demonstrieren, verantwortungsvolle KI (RAI), Langkontext, Sachlichkeit, Mathematik, MINT und vieles mehr. In ähnlicher Weise umfassen multimodale Datensätze Videos, Screenshots, Diagramme und vieles mehr.

Mit der Funktion zum Mischen von Daten können Sie Ihre eigenen Trainingsproben zur Feinabstimmung mit Stichproben aus den Nova-Datensätzen kombinieren, die zur Feinabstimmung des Nova verwendet wurden. Auf diese Weise können Sie verhindern, dass Ihr individuelles Training zu stark beansprucht wird und Sie die Nova-Fähigkeiten „katastrophal vergessen“, oder Sie können Fähigkeiten aufbauen, wenn Sie von einem neuen, vortrainierten Checkpoint aus trainieren.

Um Nova-Daten einzufügen, müssen Sie lediglich einen `data_mixing`-Block als Abschnitt auf oberster Ebene in Ihrer YAML-Rezeptdatei hinzufügen (neben `run` und `training_config`). Mischblöcke für Text und multimodale Daten haben unterschiedliche Inhalte. Bitte beachten Sie die entsprechenden Rezepte.

### Unterstützte Modelle

- Nova 2.0 Lite

### Unterstützte Modalität

- Text

- Multimodal

## Beispiele für YAML-Konfigurationen

### Konfigurationsbeispiel für Nova 2.0

```
run:
 name: my-lora-sft-run
 model_type: amazon.nova-2-lite-v1:0:256k
 model_name_or_path: nova-lite-2/prod
 data_s3_path: s3://my-bucket-name/train.jsonl
 replicas: 4
 output_s3_path: s3://my-bucket-name/outputs/
 mlflow_tracking_uri: ""
 mlflow_experiment_name: "my-lora-sft-experiment"
 mlflow_run_name: "my-lora-sft-run"

training_config:
 max_steps: 100
 save_steps: 10
 save_top_k: 5
 max_length: 32768
 global_batch_size: 32
 reasoning_enabled: true
 lr_scheduler:
 warmup_steps: 15
 min_lr: 1e-6
 optim_config:
 lr: 1e-5
 weight_decay: 0.0
 adam_beta1: 0.9
 adam_beta2: 0.95
 peft:
 peft_scheme: "lora"
 lora_tuning:
 alpha: 64
 lora_plus_lr_ratio: 64.0
```

### Mischen von Nova 2.0-Textdaten

```
data_mixing:
 dataset_catalog: sft_1p5_text_chat
 sources:
 customer_data:
 percent: 50
 nova_data:
 agents: 1
 baseline: 10
 chat: 0.5
 code: 10
 factuality: 0.1
 identity: 1
 long-context: 1
 math: 2
 rai: 1
 instruction-following: 13
 stem: 0.5
 planning: 10
 reasoning-chat: 0.5
 reasoning-code: 0.5
 reasoning-factuality: 0.5
 reasoning-instruction-following: 45
 reasoning-math: 0.5
 reasoning-planning: 0.5
 reasoning-rag: 0.4
 reasoning-rai: 0.5
 reasoning-stem: 0.4
 rag: 1
 translation: 0.1
```

## Nova 2.0 multimodales Mischen von Daten

```
data_mixing:
 dataset_catalog: sft_1p5_mm_chat
 sources:
 customer_data:
 percent: 50
 nova_data:
 charts: 1
 chat: 38
 code: 20
 docs: 3
```

```

general: 2
grounding: 1
rag: 4
screenshot: 4
text: 8
translation: 4
video: 15

```

## Checkpoints modellieren

### Nova 2.0-Checkpoints

- PRE-TRAINED[nova-lite-2/pretraining-text-RD]: Checkpoint nach konstanter Lernrate und Ramp-Down-Phasen, in denen das Modell mit Billionen von Tokens trainiert wird. [Ergebnis von Phase 2]
- MID-TRAINED[nova-lite-2/pretraining-text-CE]: Ermöglicht es Kunden mit mittleren Mengen unstrukturierter Daten, ihre Daten mit einer konservativeren Lernrate als vor dem Training einzuführen, sodass domänenspezifisches Wissen vermittelt und gleichzeitig katastrophales Vergessen vermieden wird. [Ergebnis von Phase 3]
- FINAL [nova-lite-2/prod]: Vollständig ausgerichteter letzter Checkpoint, der alle Schritte vor und nach dem Training durchlaufen hat. [Ergebnis der vierten Phase]

### Phasen der Ausbildung:

- Phase 1: PT Ckpt, anfängliches Vortraining mit konstanter Lernrate
- Stufe 2: PT Ckpt, Senkung der Lernrate
- Stufe 3: PT Ckpt, Schulung zur Erweiterung des Kontextes
- Stufe 4: Schulung im Anschluss an die Schulung und Sicherheitstraining

## Ausbildungsansätze

### Leitfaden zur Auswahl von Trainingsansätzen

| Datentyp                              | Datenvolumen | Durchführen              | Mit Checkpoint                     |
|---------------------------------------|--------------|--------------------------|------------------------------------|
| Large-scale unstrukturierte Domain-Ro | 1T+ Tokens   | Fortsetzung Pre-Training | Ende der konstanten Lernrate (CLR) |

| Datentyp                                                                                                           | Datenvolumen                | Durchführen                | Mit Checkpoint   |
|--------------------------------------------------------------------------------------------------------------------|-----------------------------|----------------------------|------------------|
| hdaten (Dokumente, Protokolle, Artikel, Code usw.)                                                                 |                             |                            |                  |
| Large-scale unstrukturierte Domain-Rohdaten                                                                        | Über 100 Milliarden Tokens  | Mid-Training               | Ende von CLR     |
| Kleinere Mengen unstrukturierter Rohdaten; Spuren strukturierter Argumentationen/CoT-Daten                         | Mehr als 1 Milliarde Tokens | Mid-Training               | Nova-Basismodell |
| Strukturierte Demonstrationen (hochwertige Input-Output-Paare, kuratierte Aufgabenanweisungen, Multi-Turn-Dialoge) | Über 1.000 Beispiele        | Betreut ( Fine-Tuning SFT) | Nova-Basismodell |

## Voraussetzungen

- Wir gehen davon aus, dass Sie bereits einen SageMaker HyperPod Cluster mit einer eingeschränkten Instanzgruppe (RIG) eingerichtet haben, die über aktive Kapazität verfügt. Wenn Sie dieses Setup noch nicht abgeschlossen haben, finden Sie weitere Informationen unter [Nova Forge einrichten mit SageMaker HyperPod](#) oder unter [Nova Forge HyperPod Setup Workshop](#), um Ihr Cluster- und RIG-Setup abzuschließen.
- Sie benötigen p5.48xlarge EC2-Instances, um dieses Rezept auszuführen. Die Mindestanzahl an Instanzen, die für die effiziente Ausführung dieses Rezepts erforderlich ist, ist wie folgt:
  - Nova Lite 2.0 - 4 p5.48xlarge
- Installieren Sie die Forge-spezifische SageMaker HyperPod CLI. Anweisungen finden Sie im [Nova Forge HyperPod Setup Workshop](#).

- Vergewissern Sie sich, dass Sie eine Verbindung zu Ihrem Cluster herstellen können mit `hyperpod get-clusters`
  - Beachten Sie, dass dieser Befehl alle SageMaker HyperPod Cluster in Ihrem Konto auflistet
- Vergewissern Sie sich, dass Ihre Trainings- und optional Validierungsdaten in einem S3-Bucket verfügbar sind, auf den die Ausführungsrolle Ihres SageMaker HyperPod Clusters zugreifen kann. Informationen zur Datenaufbereitung finden Sie im nächsten Abschnitt.
- Lassen Sie die AWS CLI Einrichtung abgeschlossen haben. Wenn Sie die Einrichtung noch nicht abgeschlossen haben, finden Sie weitere Informationen unter [Erste Schritte mit dem AWS CLI](#).
- Überprüfung: Stellen Sie nach Abschluss der Installation sicher, dass Sie die folgenden Befehle erfolgreich ausführen können

```
aws sagemaker describe-cluster --cluster-name <cluster-name> --region <region>

hyperpod connect-cluster --cluster-name cluster-name
```

## Systematischer Ansatz für eine erfolgreiche SFT

- Datenaufbereitung: Folgen Sie den festgelegten Richtlinien, um Datensätze zu erstellen, zu bereinigen oder neu zu formatieren, sodass sie die erforderliche Struktur erhalten. Stellen Sie sicher, dass Eingaben, Ausgaben und Zusatzinformationen (wie Argumentationsspuren oder Metadaten) richtig aufeinander abgestimmt und formatiert sind.
- Trainingskonfiguration: Definieren Sie, wie das Modell trainiert werden soll. Bei Verwendung von Amazon SageMaker HyperPod wird diese Konfiguration in eine YAML-Rezeptdatei geschrieben, die Folgendes beinhaltet:
  - Datenquellenpfade (Trainings- und Validierungsdatensätze)
  - Wichtige Hyperparameter (Anzahl der Trainingsschritte, Lernrate, Batchgröße)
  - Optionale Komponenten (verteilte Trainingsparameter usw.)
  - Einstellung zur Datenmischung (definiert die Proportionen der Kunden- und Nova-Datenkategorien)
- Optimieren Sie die SFT-Hyperparameter: Die von uns empfohlenen Werte für die SFT-Rezepturparameter sind ein guter Ausgangspunkt und eine solide Wahl. Wenn Sie sie für Ihren Anwendungsfall weiter optimieren möchten, führen Sie mehrere SFT-Läufe mit unterschiedlichen Parameterkombinationen durch und wählen Sie die beste aus. Sie können

Parameterkombinationen anhand der Hyper-Parameter Optimierungsmethode Ihrer Wahl auswählen. Ein einfacher Ansatz besteht darin, den Wert eines Parameters (Standard\*0.5, Standard, Standard\*2) zu variieren und gleichzeitig einen anderen Standardwert für andere Parameter beizubehalten. Wiederholen Sie dies für jeden Parameter, den Sie optimieren möchten, und iterieren Sie bei Bedarf. Die wichtigsten Parameter für LoRa sind Lernrate, Alpha (Skalierungsparameter), Anzahl der zu trainierenden Epochen und Aufwärmsschritte; für den vollen Rang sind es hauptsächlich die Lernrate, die Anzahl der Epochen und die Aufwärmsschritte.

## Sequenzierung von Experimenten und Mischen von Daten

- Wenn Sie nur SFT-Daten (train/dev/test) für eine Reihe von Aufgaben haben und Sie sich nur um die Testleistung bei diesen Aufgaben kümmern
  - Führen Sie am [FINAL] Nova-Checkpoint SFT aus, ohne zu mischen. Verwenden Sie die standardmäßigen SFT-Hyperparameter und optimieren Sie sie optional für Ihren Anwendungsfall. Monitorvalidierungsmetriken and/or bewerten Zwischenprüfpunkte für größere Datensätze.
- Wenn Sie nur über SFT-Daten (train/dev/test) für eine Reihe von Aufgaben verfügen und Ihnen die Testleistung bei diesen Aufgaben sowie allgemeine Benchmarks im gewünschten Bereich wichtig sind
  - Führen Sie zunächst SFT mit Nova-Datenmischung an einem Checkpoint vor dem Training durch (PRE-TRAINED oder MID-TRAINED Checkpoint, nicht FINAL). Durch die Verwendung eines Zwischenprüfpunkts kann das Modell Ihre benutzerdefinierten Daten besser in die firmeneigenen Daten von Nova integrieren und gleichzeitig die starken allgemeinen Funktionen beibehalten.
  - Führen Sie kürzere SFT-Trainingsläufe mit unterschiedlicher Menge an Nova-Daten in der Mischung (z. B. 10%, 25%, 50%, 75%) und Nova-Datenkategorien durch, die Ihren Anwendungsfall ergänzen (z. B. wählen Sie Anweisung nach Kategorie, wenn Sie Wert auf allgemeine Fähigkeiten legen). Überwachen Sie die Validierungsmetriken und bewerten Sie, ob das Mischen die Leistung bei allgemeinen Benchmarks verbessert. Wählen Sie den Trainingsmix und den Checkpoint aus, der zu der besten Kombination aus Leistung bei Ihrer Aufgabe und allgemeiner Leistung führt. Je nach Anwendungsfall können sowohl die Leistung der Aufgaben als auch die allgemeine Leistung durch Reinforcement Fine Tuning (RFT) weiter verbessert werden.



## Datensätze für SFT vorbereiten

Nova 2.0: Verwenden Sie das [Converse API-Format](#). Das Nova 2.0-Datenformat kann zusätzliche [Argumentationsfelder](#) enthalten.

Der Inhalt der Argumentation erfasst die zwischengeschalteten Denkschritte des Modells, bevor eine endgültige Antwort generiert wird. Verwenden Sie anschließend das `reasoningContent` Feld, um Argumentationsspuren einzufügen. Verwenden Sie Klartext für Argumentationsinhalte, vermeiden Sie Markup-Tags wie `<thinking>` und `</thinking>` sofern dies nicht ausdrücklich für Ihre Aufgabe erforderlich ist, und stellen Sie sicher, dass der Inhalt der Argumentation klar und relevant für den Problemlösungsprozess ist.

## Best Practices

- Priorisieren Sie die Datenqualität vor dem Volumen: High-quality Vielfältige und repräsentative Trainingsdaten sind wertvoller als große Mengen an Daten von geringer Qualität.
- Fügen Sie die Kategorie „Begründungserklärungen folgen“ hinzu: Wenn Sie Daten mischen, sollten Sie die Kategorie „Begründungserklärungen befolgen“ einbeziehen, um eine gute generische Leistung bei allen Aufgaben zu gewährleisten.
- Verwenden Sie Standard-Lernraten: Beginnen Sie mit den Standard-Lernraten (1e-5 für LoRa, 5e-6 für SFT mit vollem Rang) und passen Sie sie nur bei Bedarf auf der Grundlage von Validierungsmetriken an.
- Ausgewogenes Mischen von Nova-Daten: Kombinieren Sie maximal 50% der Nova-Daten, um ein optimales Verhältnis zwischen Latenz und Leistung zu erzielen. Höhere Prozentsätze können die allgemeinen Fähigkeiten verbessern, aber auch die Trainingszeit verlängern.
- Überwachen Sie die Validierungskennzahlen: Evaluieren Sie während des Trainings regelmäßig Zwischen-Checkpoints, um Überbeanspruchung oder Leistungseinbußen frühzeitig zu erkennen.
- Testen Sie anhand repräsentativer Datensätze: Stellen Sie sicher, dass Ihre Bewertungsdatensätze Ihre Anwendungsfälle in der Produktion genau wiedergeben, um eine aussagekräftige Leistungsbeurteilung zu ermöglichen.

## Vorbereitung der Konfiguration des Schulungsauftrags

### Hyperparameter

Vollständiger Satz von Hyperparametern mit Ausnahme der Datenmischung:

```

Run config
run:
 name: my-lora-sft-run
 model_type: amazon.nova-2-lite-v1:0:256k
 model_name_or_path: nova-lite-2/prod
 data_s3_path: s3://my-bucket-name/train.jsonl # SageMaker HyperPod (SMHP) only and
not compatible with SageMaker Training jobs. Replace my-bucket-name with your actual
bucket name
 replicas: 4 # Number of compute instances for training, allowed
values are 4, 8, 16, 32
 output_s3_path: s3://my-bucket-name/outputs/ # Output artifact path
(Hyperpod job-specific; not compatible with standard SageMaker Training jobs). Replace
my-bucket-name with your actual bucket name

MLFlow configs
mlflow_tracking_uri: "" # Required for MLFlow
mlflow_experiment_name: "my-lora-sft-experiment" # Optional for MLFlow. Note: leave
this field non-empty
mlflow_run_name: "my-lora-sft-run" # Optional for MLFlow. Note: leave this field non-
empty

training_config:
 max_steps: 100 # Maximum training steps. Minimal is 4.
 save_steps: 10 # How often to save checkpoints (in training steps). Must be an even
number and less than or equal to max_steps (min: 4)
 save_top_k: 5 # Keep top K best checkpoints. Note supported only
for SageMaker HyperPod jobs. Minimal is 1.
 max_length: 32768 # Sequence length (options: 8192, 16384, 32768
[default], 65536)
 global_batch_size: 32 # Global batch size (options: 32, 64, 128)
 reasoning_enabled: true # If data has reasoningContent, set to true;
otherwise False

 lr_scheduler:
 warmup_steps: 15 # Learning rate warmup steps. Recommend 15% of
max_steps
 min_lr: 1e-6 # Minimum learning rate, must be between 0.0 and 1.0

 optim_config: # Optimizer settings
 lr: 1e-5 # Learning rate, must be between 0.0 and 1.0
 weight_decay: 0.0 # L2 regularization strength, must be between 0.0
and 1.0
 adam_beta1: 0.9 # Exponential decay rate for first-moment estimates,
must be between 0.0 and 1.0

```

```

adam_beta2: 0.95 # Exponential decay rate for second-moment
estimates, must be between 0.0 and 1.0

peft: # Parameter-efficient fine-tuning (LoRA)
 peft_scheme: "lora" # Enable LoRA for PEFT
 lora_tuning:
 alpha: 64 # Scaling factor for LoRA weights (options: 32, 64,
96, 128, 160, 192),
 lora_plus_lr_ratio: 64.0 # LoRA+ learning rate scaling factor (0.0-100.0)

```

Die wichtigsten Parameter für LoRa sind Lernrate, Alpha (Skalierungsparameter), Anzahl der zu trainierenden Epochen und Aufwärmsschritte. Bei einem vollen Rang sind es hauptsächlich die Lernrate, die Anzahl der Epochen und die Aufwärmsschritte. Die Rezepte sind bereits mit den empfohlenen Standardwerten gefüllt.

## Den Datenmischblock einrichten

Fügen Sie Ihrem Rezept den Abschnitt `data_mixing` mit der entsprechenden prozentualen Verteilung auf die Datensatzkategorien hinzu.

In der folgenden Tabelle werden alle verfügbaren Nova-Datenkategorien beschrieben.

## Nova 2.0-Konfiguration mit Datenmischung

```

data_mixing:
 dataset_catalog: sft_1p5_text_chat # Nova text dataset catalog
 sources:
 customer_data:
 percent: 50 # Percent of overall mix to draw from customer data
 nova_data: # The remainder will be drawn from Nova data. The
following categories must add to 100
 agents: 1 # autonomous decision-making, task completion, goal-
oriented behavior in AI systems
 baseline: 10 # [New in Nova 1.5]
 chat: 0.5 # Conversational exchanges demonstrating natural
dialogue flow
 code: 10 # Programming examples and solutions spanning
multiple languages
 factuality: 0.1 # [New in Nova 1.5]
 identity: 1 # [New in Nova 1.5]
 long-context: 1 # [New in Nova 1.5]
 math: 2 # [New in Nova 1.5]

```

```

rai: 1 # ethical AI principles, safety considerations, and
responsible technology deployment
instruction-following: 13 # precise task execution based on varying levels of
user prompts and directives
stem: 0.5 # Technical content covering science, technology,
engineering, and mathematics
planning: 10 # Sequences demonstrating strategic thinking and
step-by-step task breakdown
reasoning-chat: 0.5
reasoning-code: 0.5
reasoning-factuality: 0.5
reasoning-instruction-following: 45
reasoning-math: 0.5
reasoning-planning: 0.5
reasoning-rag: 0.4
reasoning-rai: 0.5
reasoning-stem: 0.4
rag: 1 # combining retrieved external knowledge with
generated responses
translation: 0.1

```

In der folgenden Tabelle werden alle verfügbaren Nova-Datenkategorien beschrieben.

#### Nova 2.0-Textdatenkategorien

| Name der Kategorie | Einzelheiten der Informationen                        |
|--------------------|-------------------------------------------------------|
| agents             | Behördliche Argumentation und Erledigung von Aufgaben |
| Baseline           | Allgemeines Sprachverständnis                         |
| chat               | Fließende Konversationsfähigkeit                      |
| Code               | Codegenerierung und -verständnis                      |
| Sachlichkeit       | Sachliche Richtigkeit und Überprüfung                 |
| Identität          | Konsistente Identität und Persönlichkeit              |
| langer Kontext     | Long-context Verständnis                              |
| math               | Mathematik                                            |

| Name der Kategorie                        | Einzelheiten der Informationen                     |
|-------------------------------------------|----------------------------------------------------|
| rai                                       | Verantwortungsvolle KI-Ausrichtung                 |
| Befolgung der Anweisungen                 | Anweisung folgt                                    |
| Stamm                                     | STAMMEN                                            |
| Planung                                   | Planung und Aufgabenzerlegung                      |
| Gespräch zum Argumentieren                | Argumentation im Gespräch                          |
| Argumentationscode                        | Argumentation im Code                              |
| Argumentation — Sachlichkeit              | Sachliche Argumentation und Überprüfung            |
| Argumentation — Befolgung der Anweisungen | Begründung für die Befolgung komplexer Anweisungen |
| Argumentieren — Mathematik                | Mathematisches Denken                              |
| Argumentationsplanung                     | Begründung für Planung und Strategie               |
| Argumentationslappen                      | Argumentation mit abgerufenem Kontext              |
| Argumentation                             | Verantwortungsvolles KI-Denken                     |
| Argumentationsstamm                       | STEM-Argumentation                                 |
| Lappen                                    | Retrieval-augmented Generation                     |
| Übersetzung                               | Mehrsprachiges Verständnis und Sprachgewandtheit   |

## Multimodale Datenmischung (Nova 2.0)

```
data_mixing:
 dataset_catalog: sft_1p5_mm_chat # Nova multimodal dataset catalog
 sources:
 customer_data:
```

```
percent: 50 # Percent of overall mix to draw from customer data
nova_data: # The remainder will be drawn from Nova data. The
following categories must add to 100
 charts: 1
 chat: 38
 code: 20
 docs: 3
 general: 2
 grounding: 1
 rag: 4
 screenshot: 4
 text: 8
 translation: 4
 video: 15
```

Hinweis: Nova 2.0 beinhaltet Unterstützung für Videodatenkategorien, die in Nova 1.0 nicht verfügbar ist.

In der folgenden Tabelle werden alle verfügbaren multimodalen Datenkategorien beschrieben.

Multimodale Nova 2.0-Datenkategorien

| Name der Kategorie | Einzelheiten der Informationen                         |
|--------------------|--------------------------------------------------------|
| Diagramme          | Verständnis von Diagrammen und Datenvisualisierung     |
| chat               | Fließende multimodale Konversation                     |
| Code               | Visuelle Code-Interpretation                           |
| Dokumente          | Verstehen von Dokumenten                               |
| general            | Allgemeines visuelles Verständnis                      |
| Grounding          | Visuelle Erdung                                        |
| Lappen             | Generierung mit multimodalem Abruf                     |
| Bildschirmfoto     | Verständnis der Benutzeroberfläche und des Screenshots |
| text               | Text-based generalistische Fähigkeiten                 |

| Name der Kategorie | Einzelheiten der Informationen       |
|--------------------|--------------------------------------|
| Übersetzung        | Mehrsprachiges visuelles Verständnis |
| video              | Video-Verständnis                    |

## Einen Job starten

Sie können auch in der README-Datei nachschlagen, wenn Sie nur die wichtigsten Informationen benötigen, um den ersten SFT-Lauf zu starten.

Informationen zum Container:

### Container-Informationen und Startbefehle

| Modell   | Technik     | Unterkategorie                         | Image-URI                                                                              | Hyperpod Launcher-Befehl                                                                                                                                                                                                                                                   |
|----------|-------------|----------------------------------------|----------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Nova 2.0 | Fine-tuning | SFT-Text (mit oder ohne Datenmischung) | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-Repo verfeinern: SM-HP-SFT-V2-latest | hyperpod start-job\ -n kubeflow\ --recipe fine-tuning/nova/forging/nova_2_0nova_lite/SFT/nova_lite_2_0_p5_gpu_sft_text_with_datamix \ --override-parameters '{„instance_type“: „ml.p5.48xlarge“, „container“: „708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune |

| Modell   | Technik     | Unterkategorie                       | Image-URI                                                                              | Hyperpod<br>Launcher-Befehl                                                                                                                                                                                                                                                                              |
|----------|-------------|--------------------------------------|----------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
|          |             |                                      |                                                                                        | -repo: SM-HP-SFT-V2-latest "}" '                                                                                                                                                                                                                                                                         |
| Nova 2.0 | Fine-tuning | SFT MM (mit oder ohne Datenmischung) | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-Repo verfeinern: SM-HP-SFT-V2-latest | hyperpod start-job\ -n kubeflow\ --recipe fine-tuning/nova/forging/nova_2_0nova_lite/SFT/nova_lite_2_0_p5_gpu_sft_mm_with_datamix \ --override-parameters '{„instance_type“: „ml.p5.48xlarge“, „container“: „708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo: SM-HP-SFT-V2-latest "}" ' |

Sobald Sie alles eingerichtet haben, navigieren Sie vom Stammverzeichnis des Sagemaker-Hyperpod-CLI-Repositorys aus zum standardmäßigen Nova-Sft-Rezeptordner

- src/hyperpod\_clisagemaker\_hyperpod\_recipes/recipes\_collectionrecipes/finecdtuning/nova///-/
- Hier können Sie je nach Wahl des Basismodells wählen, ob Sie Nova 1- oder Nova 2-Rezepte ausführen möchten.

Für Nova 2.0 sft:



- Wenn Sie einen normalen SFT-Job verwenden möchten, sollten Sie in diesem Ordner ein Rezept sehen können
  - `cd///recipes/fine- src/hyperpod_cli sagemaker_hyperpod_recipes/recipes_collectiontuning/nova_2_0/nova_lite/SFT` und dann sollten Sie in diesem Ordner ein Rezept namens `nova_lite_2_0_p5_gpu_sft.yaml` sehen
- Wenn Sie `datamixing sft` Job verwenden möchten, können Sie zum Ordner `sft Forge recipes` navigieren.
  - `cd///recipes/fine- src/hyperpod_cli sagemaker_hyperpod_recipes/recipes_collection tuning/novaforge/nova_2_0/nova_lite/SFT` und Sie sollten in diesem Ordner ein Rezept mit dem Namen `nova_lite_2_0_p5_gpu_sft_text_with_datamix.yaml` sehen können
- Bearbeiten Sie die für den Job erforderlichen Abschnitte im Rezept, z. B. `name`, `data_s3_path`, `validation_s3_path`, `output_s3_path` und `max_steps`. Da wir SFT ausführen, gilt der Begriff `Epochen` hier nicht.

Die Konfigurationsdatei für die Datenmischung enthält einen zusätzlichen `data_mixing` Abschnitt, wie im folgenden Beispiel gezeigt.

```
data_mixing:
 dataset_catalog: sft_1p5_text_chat
 sources:
 customer_data:
 percent: 25
 nova_data: # The categories must add to 100
 agents: 1
 baseline: 10
 chat: 0.5
 code: 10
 factuality: 0.1
 identity: 1
 long-context: 1
 math: 2
 rai: 1
 instruction-following: 13
 stem: 0.5
 planning: 10
 reasoning-chat: 0.5
 reasoning-code: 0.5
 reasoning-factuality: 0.5
```

```
reasoning-instruction-following: 45
reasoning-math: 0.5
reasoning-planning: 0.5
reasoning-rag: 0.4
reasoning-rai: 0.5
reasoning-stem: 0.4
rag: 1
translation: 0.1
```

Die Konfiguration für das Mischen von Daten umfasst zwei Kategorien auf oberster Ebene:

- **nova\_data:** Dies ist die eigentliche Datenmischung, die in noch mehr Kategorien unterteilt ist. Es ist unbedingt erforderlich, dass sie zusammen 100% ergeben
- **customer\_data:** Dies sind Ihre Trainingsdaten, auf die im `data_s3_path` Schlüssel oben in Ihrer YAML verwiesen wird. Der hier angegebene Prozentsatz bestimmt den resultierenden Prozentsatz für `nova_data`. Beispiel: Bei der vorherigen Prozentauswahl werden für den Job während der Schulung 25% von `customer_data` und 75% von `nova_data` verwendet.

Tipp: Führen Sie `pip install -e.` erneut aus und schon können Sie Ihren Job einreichen!

Der folgende Befehl überschreibt die Parameter für das Mischen von Daten:

```
hyperpod start-job \
 -n kubeflow \
 --recipe fine-tuning/nova/forging/nova_2_0/nova_lite/SFT/
nova_lite_2_0_p5_gpu_sft_text_with_datamix \
 --override-parameters '{
 "instance_type": "ml.p5.48xlarge",
 "recipes.run.name": "nova-sft-datamixing",
 "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-
SFT-V2-latest",
 "recipes.run.data_s3_path": "s3://sft-data/sft_train_data.jsonl",
 "recipes.run.validation_data_s3_path": "s3://sft-data/sft_val_data.jsonl",
 "recipes.run.output_s3_path": "s3://sft-data/output/"
 }'
```

Ihre Ausgabe sollte einen Jobnamen wie folgt enthalten:

```
MY Desktop # % hyperpod start-job \
-n kubeflow \
--recipe fine-tuning/nova/forge/nova_2_0/nova_lite/SFT/
nova_lite_2_0_p5_gpu_sft_text_with_datamix \
--override-parameters '{
 "instance_type": "ml.p5.48xlarge",
 "recipes.run.name": "nova-sft-datamixing",
 "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-SFT-V2-latest",
 "recipes.run.data_s3_path": "s3://sft-data/sft_train_data.jsonl",
 "recipes.run.validation_data_s3_path": "s3://sft-data/sft_val_data.jsonl",
 "recipes.run.output_s3_path": "s3://sft-data/output/"
}'
```

Die Ausgabe würde wie folgt aussehen:

```
Final command: python3 /local/home/my/Downloads/sagemaker-hyperpod-cli/src/
hyperpod_cli/sagemaker_hyperpod_recipes/main.py recipes=fine-tuning/nova/forge/
nova_2_0/nova_lite/SFT/nova_lite_2_0_p5_gpu_sft_text_with_datamix cluster_type=k8s
cluster=k8s base_results_dir=/local/home/my/Downloads/sagemaker-hyperpod-cli/
results cluster.pullPolicy="IfNotPresent" cluster.restartPolicy="OnFailure"
cluster.namespace="kubeflow" instance_type="ml.p5.48xlarge"
container="708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-SFT-
V2-latest"
Prepared output directory at /local/home/my/Downloads/sagemaker-hyperpod-cli/results/
my-sft-run-wzdyn/k8s_templates
Found credentials in shared credentials file: ~/.aws/credentials
Helm script created at /local/home/my/Downloads/sagemaker-hyperpod-cli/results/my-sft-
run-wzdyn/my-sft-run-wzdyn_launch.sh
Running Helm script: /local/home/my/Downloads/sagemaker-hyperpod-cli/results/my-sft-
run-wzdyn/my-sft-run-wzdyn_launch.sh

NAME: my-sft-run-wzdyn
LAST DEPLOYED: Tue Aug 26 16:21:06 2025
NAMESPACE: kubeflow
STATUS: deployed
REVISION: 1
TEST SUITE: None
Launcher successfully generated: /local/home/my/Downloads/sagemaker-hyperpod-cli/src/
hyperpod_cli/sagemaker_hyperpod_recipes/launcher/nova/k8s_templates/SFT

{
```

```
"Console URL": "https://us-east-1.console.aws.amazon.com/sagemaker/home?region=us-east-1#/cluster-management/hyperpod-eks-ga-0703"
}
```

Sie können den Status Ihres Jobs mit `hyperpod list-pods -n kubeflow --job-name my-sft-run-wzdyn` einsehen

```
hyperpod list-pods -n kubeflow --job-name my-sft-run-wzdyn
{
 "pods": [
 {
 "PodName": "my-sft-run-wzdyn-master-0",
 "Namespace": "kubeflow",
 "Status": "Pending",
 "CreationTime": "2025-08-26 16:21:06+00:00"
 },
 {
 "PodName": "my-sft-run-wzdyn-worker-0",
 "Namespace": "kubeflow",
 "Status": "Pending",
 "CreationTime": "2025-08-26 16:21:06+00:00"
 }
]
}
```

oder verwenden Sie direkt den Befehl `kubectl`, um sie zu finden.

Zum Beispiel

```
kubectl get pods -o wide -w -n kubeflow | (head -n1 ; grep my-sft-run)
```

| NAME                                             | READY  | STATUS         |
|--------------------------------------------------|--------|----------------|
| RESTARTS   AGE   IP   NODE                       |        | NOMINATED NODE |
| READINESS GATES                                  |        |                |
| my-sft-run-5suc8-master-0                        | 0/1    | Completed 0    |
| 3h23m 172.31.32.132 hyperpod-i-00b3d8a1bf25714e4 | <none> | <none>         |
| my-sft-run-5suc8-worker-0                        | 0/1    | Completed 0    |
| 3h23m 172.31.44.196 hyperpod-i-0aa7ccfc2bd26b2a0 | <none> | <none>         |
| my-sft-run-5suc8-worker-1                        | 0/1    | Completed 0    |
| 3h23m 172.31.46.84 hyperpod-i-026df6406a7b7e55c  | <none> | <none>         |

|                                                 |        |           |        |
|-------------------------------------------------|--------|-----------|--------|
| my-sft-run-5suc8-worker-2                       | 0/1    | Completed | 0      |
| 3h23m 172.31.28.68 hyperpod-i-0802e850f903f28f1 | <none> |           | <none> |

Profi-Tipp: Stellen Sie sicher, dass Sie immer das Flag `-o wide` verwenden, da der EKS-Knoten, auf dem der Job ausgeführt wird, Ihnen hilft, Ihre Logs in der Benutzeroberfläche noch schneller zu finden AWS

## Überwachen von Aufträgen

Sie können Ihre Logs auf drei Arten einsehen:

### Verwenden CloudWatch

Ihre Protokolle sind in Ihrem Amazon Web Services Services-Konto verfügbar, das den Hyperpod-Cluster darunter CloudWatch enthält. Um sie in Ihrem Browser anzuzeigen, navigieren Sie in Ihrem Konto zur CloudWatch Startseite und suchen Sie nach Ihrem Clusternamen. Wenn Ihr Cluster beispielsweise `my-hyperpod-rig` heißen würde, hätte die Protokollgruppe das Präfix:

- Protokollgruppe: `//aws/sagemaker/{UUID} Clusters/my-hyperpod-rig`
- Sobald Sie in der Protokollgruppe sind, können Sie Ihr spezifisches Protokoll anhand der Knoteninstanz-ID finden, z. B. - `hyperpod-i-00b3d8a1bf25714e4`.
  - `i-00b3d8a1bf25714e4` steht hier für den hyperpod-freundlichen Computernamen, auf dem Ihr Trainingsjob ausgeführt wird. Erinnern Sie sich, wie wir in der vorherigen Ausgabe des Befehls `kubectl get pods -o wide -w -n kubeflow | (head -n1; grep my-sft-run)` eine Spalte namens `NODE` erfasst haben.
  - Der „Master“-Knotenlauf lief in diesem Fall auf `hyperpod-i-00b3d8a1bf25714e4` und daher verwenden wir diese Zeichenfolge, um die anzuzeigende Protokollgruppe auszuwählen. Wählen `SagemakerHyperPodTrainingJob/rig-group` Sie den aus, auf dem `[NODE]` steht

### CloudWatch Insights verwenden

Wenn Sie Ihren Jobnamen griffbereit haben, können Sie alle Logs unter `//aws/sagemakerClusters/my-hyperpod-rig/{UUID}` abfragen, um das einzelne Protokoll zu finden.

### SFT

```
fields @timestamp, @message, @logStream, @log
```

```
| filter @message like /(?!i)Starting SFT Job/
| sort @timestamp desc
| limit 100
```

Um den Job abzuschließen, ersetzen Sie „SFT-Job starten“ durch „SFT-Job abgeschlossen“.

Dann können Sie aus den Ergebnissen den Knoten auswählen, auf dem „Epoch 0“ steht, da dies Ihr Master-Knoten sein wird.

Mit dem AWS CLI

Sie können wählen, ob Sie Ihre Protokolle mit dem verfolgen möchten AWS CLI. Bevor Sie dies tun, überprüfen Sie bitte Ihre AWS CLI Version mit `aws --version`. Es wird auch empfohlen, dieses Utility-Skript zu verwenden, das bei der Live-Protokollverfolgung in Ihrem Terminal hilft

für V1:

```
aws logs get-log-events \
 --log-group-name /aws/sagemaker/YourLogGroupName \
 --log-stream-name YourLogStream \
 --start-from-head | jq -r '.events[].message'
```

für V2:

```
aws logs tail /aws/sagemaker/YourLogGroupName \
 --log-stream-name YourLogStream \
 --since 10m \
 --follow
```

## MLflow einrichten

Sie können Metriken über MLflow verfolgen.

### Erstellen Sie eine MLFlow-App

Verwenden der Studio-Benutzeroberfläche: Wenn Sie einen Trainingsjob über die Studio-Benutzeroberfläche erstellen, wird automatisch eine standardmäßige MLflow-Anwendung erstellt und standardmäßig unter Erweiterte Optionen ausgewählt.

Verwenden von CLI: Wenn Sie die CLI verwenden, müssen Sie eine MLflow-App erstellen und sie als Eingabe an die API-Anfrage für den Trainingsjob übergeben.

```
mlflow_app_name="<enter your MLflow app name>"
role_arn="<enter your role ARN>"
bucket_name="<enter your bucket name>"
region="<enter your region>"

mlflow_app_arn=$(aws sagemaker create-mlflow-app \
 --name $mlflow_app_name \
 --artifact-store-uri "s3://$bucket_name" \
 --role-arn $role_arn \
 --region $region)
```

Greifen Sie auf die MLFlow-App zu

Verwenden von CLI: Erstellen Sie eine vorsignierte URL für den Zugriff auf die Benutzeroberfläche der MLflow-App:

```
aws sagemaker create-presigned-mlflow-app-url \
 --arn $mlflow_app_arn \
 --region $region \
 --output text
```

Nachdem MLflow eingerichtet ist, können Sie den URI in Ihrem Rezept übergeben oder Override verwenden, wenn Sie den Job starten.

## Evaluieren Sie Ihr Modell nach SFT

### Voraussetzungen

- Checkpoint S3-URI aus der Datei manifest.json Ihres Trainingsjobs (für trainierte Modelle)
- Der Bewertungsdatensatz wurde im richtigen Format auf S3 hochgeladen
- S3-Pfad für die Evaluierungsergebnisse ausgeben

Sofort einsatzbereite Benchmarks: Verwenden Sie sofort einsatzbereite Benchmarks, um die Leistung bei allgemeinen Aufgaben zu validieren. Weitere Informationen finden Sie unter [Evaluierung von Nova-Modellen](#) auf. HyperPod

## Verwenden Ihrer eigenen Daten

Sie können Ihre benutzerdefinierten Daten auch bereitstellen, indem Sie sie im folgenden Format formatieren und dann die folgenden Container verwenden, um Inferenzergebnisse zusammen mit Protokollwahrscheinlichkeiten für Kalibrierungen zu erhalten, falls erforderlich.

Erstellen Sie jsonl pro Aufgabe mit der folgenden Struktur:

```
{
 "metadata": "{key:4, category:'apple'}",
 "system": "arithmetic-patterns, please answer the following with no other words: ",
 "query": "What is the next number in this series? 1, 2, 4, 8, 16, ?",
 "response": "32"
}
```

Die während der Inferenzphase der Evaluierung generierten Ergebnisse werden folgende Struktur haben:

```
{
 "prompt": "[{'role': 'system', 'content': 'arithmetic-patterns, please answer the following with no other words: '}, {'role': 'user', 'content': 'What is the next number in this series? 1, 2, 4, 8, 16, ?'}]",
 "inference": "['32']",
 "gold": "32",
 "metadata": "{key:4, category:'apple'}"
}
```

Beschreibungen der Felder:

- Eingabeaufforderung: Formatierte Eingabe wurde an das Modell gesendet
- Inferenz: Die generierte Antwort des Modells
- Gold: Richtige Antwort aus dem Eingabedatensatz erwartet, Antwortfeld aus der Eingabe
- Metadaten: Optionale Metadaten, die von der Eingabe übergeben wurden

Die Evaluierungskonfiguration wird vorbereitet

Befehl zum Starten des Evaluierungsjobs. Verwenden Sie „--override-parameters“, um einen beliebigen Eintrag aus dem Rezept zu ändern.



```
hyperpod start-job -n kubeflow \
 --recipe evaluation/nova/nova_micro_p5_48xl_bring_your_own_dataset_eval \
 --override-parameters '{
 "instance_type": "p5.48xlarge",
 "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-HP-Eval-latest",
 "recipes.run.name": "<your-eval-job-name>",
 "recipes.run.model_name_or_path": "<checkpoint-s3-uri>",
 "recipes.run.output_s3_path": "s3://<your-bucket>/eval-results/",
 "recipes.run.data_s3_path": "s3://<your-bucket>/eval-data.jsonl"
 }'
```

Ihr Evaluierungsjob wird gestartet

Befehle zum Starten von Job für verschiedene Rezepte mit entsprechenden Bildern.

Befehle zum Starten von Evaluierungsaufträgen

| Modell   | Technik   | Unterkategorie | Image-URI                                                                           | Befehl                                                                                                                                                                                                                                           |
|----------|-----------|----------------|-------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Nova 2.0 | Bewertung | Eval           | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-HP-Eval-latest | hyperpod start-job -n kubeflow\ --recipe evaluation/nova/nova_micro_p5_48xl_bring_your_own_dataset_eval \ --override-parameters '{ „instance_type“: „ml.p5.48xlarge“, „container“: „708977205387.dkr.ecr.us-east-1.amazonaws.com/novaSM-HP-Eval- |

| Modell | Technik | Unterkategorie | Image-URI | Befehl                             |
|--------|---------|----------------|-----------|------------------------------------|
|        |         |                |           | -latest-evaluation<br>-repo: "}" ' |

## Gelernte Erkenntnisse und Tipps

- Die Qualität des SFT-Datensatzes ist entscheidend. Sie sollten alle Anstrengungen unternehmen, um Daten von geringer Qualität herauszufiltern. Wenn Sie über eine kleine Teilmenge von Daten verfügen, die sowohl in Bezug auf Komplexität als auch Genauigkeit von außergewöhnlich hoher Qualität sind, sollten Sie erwägen, diese gegen Ende des Trainings zu platzieren, damit das Modell besser konvergiert.
- Wir nutzen sowohl Text- als auch multimodale (MM) Datensätze für die Datenmischung. Unsere Experimente mit Textdatensätzen zeigen, dass das Hinzufügen der von Nova entwickelten Kategorie „Argumentation-Instruction-Following“ die Leistung bei generischen Benchmarks erheblich verbessert. Wir empfehlen, diese Kategorie in Ihre Strategie zur Datenmischung aufzunehmen, wenn Sie generische Benchmarks bevorzugen, bei denen nach der SFT-Analyse mit Ihren Datensätzen eine Regression vorgenommen wird.
- Bei MM-Datensätzen deuten unsere Experimente darauf hin, dass die Einbeziehung von mehr als 20% der Videokategorien in den Mix vorteilhaft ist, um die generische Benchmark-Leistung aufrechtzuerhalten.
- Darüber hinaus reagiert SFT mit Datenmischung sehr empfindlich auf die Lernrate, weshalb unsere Ergebnisse eine Feinabstimmung mit der Standard-Lernrate, d. h. 1e-5 für LoRa und 5e-6 für FR, nahelegen.
- Schließlich gibt es einen Kompromiss zwischen Latenz und Leistung, wenn Sie Nova-eigene Datensätze mischen. Unseren Ergebnissen zufolge sollten Sie also ein ausgewogenes Verhältnis von maximal 50% erzielen.

## Datenmischung bei SageMaker Trainingsjobs

Mit der Datenmischung von Amazon Nova Forge können Sie Ihre benutzerdefinierten Trainingsdaten während der überwachten Feinabstimmung (SFT) mit den firmeneigenen Trainingsdaten von Amazon Nova kombinieren. Dies trägt dazu bei, die allgemeinen Funktionen des Modells beizubehalten und es gleichzeitig auf Ihre Zieldomäne zu spezialisieren.

 Note

Das Mischen von Daten bei SageMaker Trainingsjobs (serverlos) wird derzeit für Nova 2 Lite-Nur-Text-SFT unterstützt, sowohl mit LoRa als auch mit Full-Rank-Feinabstimmung.

Voraussetzungen

- Amazon Nova Forge-Abonnement. Wenden Sie AWS sich für den Zugriff an Ihren Ansprechpartner.
- Eine IAM-Ausführungsrolle mit `AmazonSageMakerFullAccess` und Berechtigungen für den Zugriff auf Amazon Nova Forge, Amazon S3 S3-Buckets und Ihren Trainingsdaten-Bucket. Die Ausführungsrolle muss Amazon S3 S3-Lesezugriff auf die Amazon Nova Forge-Abonnement-Buckets haben, damit der Service Ihren Abonnementstatus überprüfen kann. Die erforderliche IAM-Richtlinie finden Sie unter [IAM-Richtlinienanforderungen für Amazon Nova-Rezepte](#).
- Trainingsdaten wurden im Converse API-Format auf Amazon S3 hochgeladen. Einzelheiten zum Datenformat finden Sie unter [Vorbereiten von Trainingsdaten für Nova 2.0](#).
- Ein ARN für eine Modellpaketgruppe in Ihrem Konto.
- Ein Basismodell ARN vom SageMaker AI Hub.
- (Optional) Das `amzn-nova-forge` Python-SDK ist installiert. Installationsanweisungen finden Sie unter [Installation](#).

Hyperparameter

Wenn Sie die API oder CLI direkt verwenden, müssen alle Hyperparameterwerte als Zeichenfolgen übergeben werden. Die SDKs behandeln die Typkonvertierung intern. Das Mischen von Daten wird durch die Einbeziehung des `customer_data_percent` Hyperparameters ermöglicht.

Parameter für das Mischen von Daten

| Parameter                          | Typ                   | Description                                                                                                                                               |
|------------------------------------|-----------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------|
| <code>customer_data_percent</code> | Zeichenfolge (0 —100) | Prozentualer Anteil des gesamten Trainingsmixes, der aus Ihren Daten ermittelt wurde. Der Rest stammt aus den kuratierten Trainingsdaten von Amazon Nova. |

Die Einstellung `customer_data_percent` auf "50" bedeutet, dass 50% der Trainingsbeispiele aus Ihrer JSONL-Datei und 50% aus Amazon Nova stammen. Auf einstellen, "100" um das Mischen zu deaktivieren (nur Kundendaten). Nur "0" für Amazon Nova-Daten eingestellt.

Sie können auch die Verteilung von Amazon Nova-Daten über Kategorien hinweg steuern, indem Sie einzelne `nova_<category>_percent` Hyperparameter übergeben. Wenn angegeben, müssen sich die `nova_*_percent` Werte summieren und 100 ergeben. Wenn Sie sie weglassen, wird die Standardverteilung verwendet.

#### Important

Wenn Sie die Prozentsätze für Kategorien anpassen, müssen Sie Werte für alle 23 Kategorien angeben, die zusammen 100 ergeben müssen. Setzen Sie unbenutzte Kategorien auf "0" explizit.

Beispiel: Standardverteilung nach Kategorien

```
{
 "customer_data_percent": "50",
 "nova_agents_percent": "1",
 "nova_baseline_percent": "10",
 "nova_chat_percent": "0.5",
 "nova_code_percent": "10",
 "nova_factuality_percent": "0.1",
 "nova_identity_percent": "1",
 "nova_long-context_percent": "1",
 "nova_math_percent": "2",
 "nova_rai_percent": "1",
 "nova_instruction-following_percent": "13",
 "nova_stem_percent": "0.5",
 "nova_planning_percent": "10",
 "nova_reasoning-chat_percent": "0.5",
 "nova_reasoning-code_percent": "0.5",
 "nova_reasoning-factuality_percent": "0.5",
 "nova_reasoning-instruction-following_percent": "45",
 "nova_reasoning-math_percent": "0.5",
 "nova_reasoning-planning_percent": "0.5",
 "nova_reasoning-rag_percent": "0.4",
 "nova_reasoning-rai_percent": "0.5",
 "nova_reasoning-stem_percent": "0.4",
}
```

```

"nova_rag_percent": "1",
"nova_translation_percent": "0.1",
"max_steps": "100",
"global_batch_size": "32"
}

```

In der folgenden Tabelle sind alle verfügbaren Kategorie-Hyperparameter aufgeführt.

| Hyperparameter                     | Description                                           |
|------------------------------------|-------------------------------------------------------|
| nova_agents_percent                | Behördliche Argumentation und Erledigung von Aufgaben |
| nova_baseline_percent              | Allgemeines Sprachverständnis                         |
| nova_chat_percent                  | Fließende Konversationsfähigkeit                      |
| nova_code_percent                  | Codegenerierung und -verständnis                      |
| nova_factuality_percent            | Sachliche Richtigkeit und Überprüfung                 |
| nova_identity_percent              | Konsistente Identität und Persönlichkeit              |
| nova_instruction-following_percent | Anweisung folgt                                       |
| nova_long-context_percent          | Long-context Verständnis                              |
| nova_math_percent                  | Mathematik                                            |
| nova_planning_percent              | Planung und Aufgabenzerlegung                         |
| nova_rag_percent                   | Retrieval-augmented Generierung                       |
| nova_rai_percent                   | Verantwortungsvolle KI-Ausrichtung                    |
| nova_stem_percent                  | STAMMEN                                               |
| nova_translation_percent           | Mehrsprachiges Verständnis und Sprachkompetenz        |
| nova_reasoning-chat_percent        | Argumentation im Gespräch                             |

| Hyperparameter                                            | Description                                      |
|-----------------------------------------------------------|--------------------------------------------------|
| <code>nova_reasoning-code_percent</code>                  | Argumentation im Code                            |
| <code>nova_reasoning-factuality_percent</code>            | Sachliche Argumentation und Überprüfung          |
| <code>nova_reasoning-instruction-following_percent</code> | Begründung für komplexe Anweisungen im Anschluss |
| <code>nova_reasoning-math_percent</code>                  | Mathematisches Denken                            |
| <code>nova_reasoning-planning_percent</code>              | Argumentation für Planung und Strategie          |
| <code>nova_reasoning-rag_percent</code>                   | Argumentation mit dem abgerufenen Kontext        |
| <code>nova_reasoning-rai_percent</code>                   | Verantwortungsvolles KI-Denken                   |
| <code>nova_reasoning-stem_percent</code>                  | STEM-Argumentation                               |

### Note

Wenn Sie `nova_*_percent` Hyperparameter angeben, müssen Sie alle 23 Kategorien mit Werten angeben, deren Summe 100 ergibt. Wenn Sie keine `nova_*_percent` Hyperparameter angeben, wird die Standardverteilung verwendet.

## Trainingsparameter

Die folgenden Parameter gelten sowohl für die LoRa-Feinabstimmung als auch für die Feinabstimmung mit vollem Rang, sofern nicht anders angegeben.

| Parameter               | Typ            | Standard                          | Beschreibung                                                                                                                                                              |
|-------------------------|----------------|-----------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| max_steps               | Ganzzahl       | 10(LoRa)/<br>(voller Rang)<br>100 | Anzahl der Trainingsschritte.                                                                                                                                             |
| global_batch_size       | Ganzzahl       | 32                                | Chargengröße. Optionen: 32, 64, 128, 256, 512, 1024.                                                                                                                      |
| learning_rate           | Gleitkommazahl | 1e-05                             | Lernrate.                                                                                                                                                                 |
| warmup_steps            | Ganzzahl       | 15                                | Schritte zum Aufwärmen mit Lerngeschwindigkeit.                                                                                                                           |
| min_lr                  | Gleitkommazahl | 1e-06                             | Minimale Lernrate für den Scheduler.                                                                                                                                      |
| weight_decay            | Gleitkommazahl | 0.0                               | Stärke der L2-Regularisierung.                                                                                                                                            |
| save_steps              | Ganzzahl       | 10(LoRa)/<br>(voller Rang)<br>100 | Wie oft Checkpoints in Trainingsschritten gespeichert werden sollen. Dies muss eine gerade Zahl sein.                                                                     |
| max_context_length      | Ganzzahl       | 32768                             | Maximale Sequenzlänge in Tokens.                                                                                                                                          |
| reasoning_enabled       | Boolesch       | true                              | Aktivieren Sie den Argumentationsmodus. Stellen Sie ein <code>true</code> , ob Ihre Daten <code>reasoningContent</code> Felder enthalten, <code>false</code> andernfalls. |
| validation_data_s3_path | Zeichenfolge   | –                                 | Optionaler Amazon S3 S3-Pfad zu einer Validierungs-JSONL-Datei. Falls angegeben                                                                                           |

| Parameter                       | Typ            | Standard | Beschreibung                                                                                                                                       |
|---------------------------------|----------------|----------|----------------------------------------------------------------------------------------------------------------------------------------------------|
|                                 |                |          | , wird der Validierungsverlust in Schritten berechnet. <code>val_check_interval</code>                                                             |
| <code>val_check_interval</code> | Ganzzahl       | –        | Führen Sie die Validierung alle N Trainings schritte durch. Gilt nur, <code>validation_data_s3_path</code> wenn angegeben.                         |
| <code>fine_tune_d_model</code>  | Gleitkommazahl | 1.0      | Gewicht des fein abgestimmten Checkpoints bei der Modellzusammenführung Wählen Sie diese Option, um die Modellzusammenführung 1.0 zu deaktivieren. |

## LoRa-Parameter

| Parameter                        | Typ            | Standard | Beschreibung                                                       |
|----------------------------------|----------------|----------|--------------------------------------------------------------------|
| <code>alpha</code>               | Ganzzahl       | 64       | LoRa-Alpha-Skalierungsfaktor. Optionen: 32, 64, 96, 128, 160, 192. |
| <code>learning_rate_ratio</code> | Gleitkommazahl | 64.0     | Skalierungsfaktor für die LoRa+-Lernrate                           |

## Verwenden des Amazon Nova Forge SDK

Mit dem `amzn-nova-forge` Python-SDK können Sie auch serverlose SFT-Jobs mit Datenmischung einreichen. Installationsanweisungen finden Sie unter [Installation des Amazon Nova Forge-SDK](#).

```
from amzn_nova_forge.trainer import ForgeTrainer
from amzn_nova_forge.manager import SMTJServerlessRuntimeManager
from amzn_nova_forge.core import ForgeConfig
from amzn_nova_forge.core.enums import Model, TrainingMethod

infra = SMTJServerlessRuntimeManager(
 model_package_group_name="your-model-package-group",
 execution_role="arn:aws:iam::123456789012:role/YourRole",
)
```



```

trainer = ForgeTrainer(
 model=Model.NOVA_LITE_2,
 method=TrainingMethod.SFT_LORA,
 infra=infra,
 training_data_s3_path="s3://your-bucket/data/train.jsonl",
 data_mixing_enabled=True,
 config=ForgeConfig(output_s3_path="s3://your-bucket/output/"),
)

Set data mixing percentages – all 23 nova categories must be specified and sum to 100
trainer.data_mixing.set_config({
 "customer_data_percent": 50,
 "nova_agents_percent": 60,
 "nova_chat_percent": 40,
 "nova_baseline_percent": 0,
 "nova_code_percent": 0,
 "nova_factuality_percent": 0,
 "nova_identity_percent": 0,
 "nova_long-context_percent": 0,
 "nova_math_percent": 0,
 "nova_rai_percent": 0,
 "nova_instruction-following_percent": 0,
 "nova_stem_percent": 0,
 "nova_planning_percent": 0,
 "nova_reasoning-chat_percent": 0,
 "nova_reasoning-code_percent": 0,
 "nova_reasoning-factuality_percent": 0,
 "nova_reasoning-instruction-following_percent": 0,
 "nova_reasoning-math_percent": 0,
 "nova_reasoning-planning_percent": 0,
 "nova_reasoning-rag_percent": 0,
 "nova_reasoning-rai_percent": 0,
 "nova_reasoning-stem_percent": 0,
 "nova_rag_percent": 0,
 "nova_translation_percent": 0,
})

Verify the config before training
current_config = trainer.data_mixing.get_config()
print(f>Data mixing config: {current_config}")

result = trainer.train(job_name="sft-datamix-serverless")

```

```
print(f"Job ID: {result.job_id}")
```

Für eine vollständige Feinabstimmung verwenden Sie `TrainingMethod.SFT_FULL` statt `TrainingMethod.SFT_LORA`.

## Verwenden des Python-SDK (SageMaker)

Sie können serverlose SFT-Jobs mit Datenmischung mithilfe der SageMaker AI Python SFTTrainer SDK-Klasse einreichen.

```
from sagemaker.train.sft_trainer import SFTTrainer
from sagemaker.train.common import TrainingType
from sagemaker.core.helper.session_helper import Session

sagemaker_session = Session()

trainer = SFTTrainer(
 model="nova-textgeneration-lite-v2",
 training_type=TrainingType.FULL,
 model_package_group="my-custom-models",
 training_dataset="s3://my-bucket/data/train.jsonl",
 s3_output_path="s3://my-bucket/output/",
 sagemaker_session=sagemaker_session,
 role="arn:aws:iam::123456789012:role/SageMakerExecutionRole",
)

Set standard training hyperparameters
trainer.hyperparameters.max_steps = 100
trainer.hyperparameters.learning_rate = 5e-6

Set data mixing percentages – nova percents must sum to 100
trainer.hyperparameters.customer_data_percent = 70
trainer.hyperparameters.nova_code_percent = 30
trainer.hyperparameters.nova_math_percent = 20
trainer.hyperparameters.nova_planning_percent = 10
setattr(trainer.hyperparameters, 'nova_instruction-following_percent', 10)
setattr(trainer.hyperparameters, 'nova_reasoning-instruction-following_percent', 20)
setattr(trainer.hyperparameters, 'nova_reasoning-math_percent', 10)

Zero out unused categories
trainer.hyperparameters.nova_agents_percent = 0
trainer.hyperparameters.nova_baseline_percent = 0
trainer.hyperparameters.nova_chat_percent = 0
```

```

trainer.hyperparameters.nova_factuality_percent = 0
trainer.hyperparameters.nova_identity_percent = 0
trainer.hyperparameters.nova_stem_percent = 0
trainer.hyperparameters.nova_rai_percent = 0
trainer.hyperparameters.nova_rag_percent = 0
trainer.hyperparameters.nova_translation_percent = 0
for category in ['nova_long-context_percent', 'nova_reasoning-chat_percent',
 'nova_reasoning-code_percent', 'nova_reasoning-factuality_percent',
 'nova_reasoning-planning_percent', 'nova_reasoning-rag_percent',
 'nova_reasoning-rai_percent', 'nova_reasoning-stem_percent']:
 setattr(trainer.hyperparameters, category, 0)

Start training
training_job = trainer.train(wait=True)
print(f"Training job: {training_job.training_job_name}")

```

### Note

Einige Parameternamen enthalten Bindestriche (z. B.). `nova_instruction-following_percent` Verwenden Sie `setattr()`, um diese festzulegen. Parameter ohne Bindestriche können direkt gesetzt werden (z. B. `trainer.hyperparameters.nova_code_percent = 30`).

Verwenden Sie für die LoRa-Feinabstimmung anstelle von `TrainingType.LORA` `TrainingType.FULL`

Verwenden Sie den AWS CLI

Die folgende Befehlsstruktur zeigt, wie Sie einen serverlosen SFT-Job mit Datenmischung mithilfe von senden. AWS CLI

```

aws sagemaker create-training-job \
 --region <region> \
 --training-job-name <job-name> \
 --role-arn <execution-role-arn> \
 --hyper-parameters '<hyperparameters-json>' \
 --input-data-config '<input-config-json>' \
 --output-data-config '<output-config-json>' \
 --stopping-condition '{"MaxRuntimeInSeconds": 432000}' \
 --serverless-job-config '<serverless-config-json>' \

```

```
--model-package-config '<model-package-config-json>'
```

## Konfiguration für serverlose Jobs

Übergeben Sie den folgenden JSON-Code als Wert von `--serverless-job-config`. Dadurch wird Amazon Nova Forge mitgeteilt, welches Modell optimiert und welche Trainingsmethode verwendet werden soll.

```
{
 "BaseModelArn": "<base-model-arn>",
 "AcceptEula": true,
 "JobType": "FineTuning",
 "CustomizationTechnique": "SFT",
 "Peft": "LORA"
}
```

| Feld                   | Description                                                                                                    |
|------------------------|----------------------------------------------------------------------------------------------------------------|
| BaseModelArn           | ARN des Nova 2 Lite-Modells in SageMaker AI Hub.                                                               |
| AcceptEula             | Muss true die Modell-EULA akzeptieren.                                                                         |
| JobType                | FineTuning                                                                                                     |
| CustomizationTechnique | SFT                                                                                                            |
| Peft                   | LORA für die LoRa-Feinabstimmung. Lassen Sie dieses Feld für die Feinabstimmung in vollem Umfang komplett weg. |

## Konfiguration des Modellpakets

Übergeben Sie das folgende JSON als Wert von `--model-package-config`. Der Checkpoint für das trainierte Modell ist als Modellpaketversion in der angegebenen Gruppe registriert.

```
{
 "ModelPackageGroupArn": "arn:aws:sagemaker:<region>:<account>:model-package-group/<group-name>"
}
```

## Eingabedatenkonfiguration

### Note

Beim Mischen von Daten bei SageMaker Trainingsaufträgen (serverlos) wird nur das Konversionsformat „Nur Text“ unterstützt. Multimodale Konversationsmanifeste (die Bilder oder Videos enthalten) werden nicht unterstützt.

Übergeben Sie den folgenden JSON-Code als Wert von. `--input-data-config`

```
[{
 "ChannelName": "train",
 "DataSource": {
 "S3DataSource": {
 "S3DataType": "Converse",
 "S3Uri": "s3://<bucket>/<path>/training-data.jsonl",
 "S3DataDistributionType": "FullyReplicated"
 }
 },
 "CompressionType": "None",
 "RecordWrapperType": "None"
}]
```

`S3DataType` muss `Converse` für Amazon Nova SFT-Daten sein. Die Trainingsdaten verwenden dasselbe `Converse-API-JSONL`-Format wie das Standard-SFT-Format von Nova 2 Lite. Auf `eingestelltCompressionType`, `None` weil die Trainingsdaten reines JSONL sind und nicht komprimiert sind. Auf `gesetztRecordWrapperType`, `None` weil die Daten nicht im `RecordIO`-Format verpackt sind.

Das folgende vollständige Beispiel sendet einen LoRa-SFT-Job mit einer Datenmischung von 50%.

```
aws sagemaker create-training-job \
 --region us-east-1 \
 --training-job-name "my-sft-datamix-lora" \
 --role-arn "arn:aws:iam::<account>:role/<execution-role>" \
 --hyper-parameters '{
 "customer_data_percent": "50",
 "max_steps": "100",
 "global_batch_size": "32",
 "learning_rate": "1e-05",
```

```

 "warmup_steps": "15",
 "min_lr": "1e-06",
 "weight_decay": "0.0",
 "save_steps": "10",
 "reasoning_enabled": "true",
 "alpha": "64"
}' \
--input-data-config '{
 "ChannelName": "train",
 "DataSource": {
 "S3DataSource": {
 "S3DataType": "Converse",
 "S3Uri": "s3://<bucket>/training-data.jsonl",
 "S3DataDistributionType": "FullyReplicated"
 }
 },
 "CompressionType": "None",
 "RecordWrapperType": "None"
}' \
--output-data-config '{
 "S3OutputPath": "s3://<bucket>/output",
 "CompressionType": "NONE"
}' \
--stopping-condition '{"MaxRuntimeInSeconds": 432000}' \
--serverless-job-config '{
 "BaseModelArn": "<base-model-arn>",
 "AcceptEula": true,
 "JobType": "FineTuning",
 "CustomizationTechnique": "SFT",
 "Peft": "LORA"
}' \
--model-package-config '{
 "ModelPackageGroupArn": "arn:aws:sagemaker:us-east-1:<account>:model-package-group/
<group-name>"
}' \
--output text --query 'TrainingJobArn'

```

Für eine vollständige Feinabstimmung sollten Sie Hyperparameter weglassen und aus ihnen entfernen "Peft": "LORA". --serverless-job-config "alpha"

Überprüfen Sie den Auftragsstatus

```
aws sagemaker describe-training-job \
```

```
--region us-east-1 \
--training-job-name "my-sft-datamix-lora" \
--query '{Status:TrainingJobStatus,Secondary:SecondaryStatus,Reason:FailureReason}' \
--output json
```

## Best Practices

- Beginnen Sie mit 50% Kundendaten als ausgewogenem Ausgangspunkt. Höhere Prozentsätze erhöhen die Spezialisierung auf Fachgebiete, verringern jedoch die allgemeine Erhaltung der Fähigkeiten.
- Wenn Sie Daten mischen, um bei allgemeinen Aufgaben eine gute Leistung zu erzielen, sollten Sie auch die folgenden Argumentationsanweisungen berücksichtigen.
- Verwenden Sie die Standard-Lernraten — 1e-5 für LoRa, 5e-6 für vollen Rang. Passen Sie nur auf der Grundlage von Validierungsmetriken an.

## Einschränkungen

- Text-only SFT — Multimodales Mischen von Daten wird bei SageMaker Training Jobs nicht unterstützt.
- Nur Nova 2 Lite — Andere Modellgrößen werden für das Mischen von Daten bei SageMaker Trainingsjobs nicht unterstützt.
- Category-level Steuerung — Wenn Sie die Prozentsätze für Kategorien anpassen, müssen Sie alle 23 Kategorien mit Werten angeben, deren Summe 100 ergibt. Setzen Sie unbenutzte Kategorien auf explizit. "0"
- Parameter „Keine Replikate“ — ResourceConfig wird auf Serverless nicht unterstützt. Replikate sind nicht konfigurierbar.

## Reinforcement Learning

### Note

Eine ausführliche Dokumentation wird nach dem Abonnieren zur Verfügung gestellt

Nova Forge bietet erweiterte Reinforcement-Learning-Funktionen mit der Option, Remote-Belohnungsfunktionen in Ihrer eigenen Umgebung zu verwenden. Kunden können wählen, ob sie

ihren eigenen Endpunkt integrieren, um die Validierung durchzuführen, um sofort Feedback aus der Praxis zu erhalten, oder sogar ihren eigenen Orchestrator verwenden, um behördliche Multi-Turn-Evaluierungen in Ihrer Umgebung zu koordinieren.

## Verwenden Sie Ihren eigenen Orchestrator für behördliche Multi-Turn-Evaluierungen

Für Forge-Benutzer, die Multi-Turn-Konversationen oder Prämienfunktionen mit einer Wartezeit von mehr als 15 Minuten benötigen, bietet Nova Forge BYOO-Funktionen (Bring Your Own Orchestration). Auf diese Weise können Sie behördliche Multiturn-Evaluierungen in Ihrer Umgebung koordinieren (z. B. mithilfe von Chemie-Tools zur Bewertung molekularer Designs oder Robotiksimulationen, die effiziente Aufgabenerfüllung belohnen und Kollisionen bestrafen).

### Themen

- [Übersicht über die Architektur](#)
- [Einrichtung und Ausführung](#)

## Übersicht über die Architektur

Die BYOO-Architektur bietet über eine vom Kunden verwaltete Infrastruktur die volle Kontrolle über den Rollout- und Generierungsprozess.

### Schulung VPC:

- Rollout: Koordiniert die Schulung, indem die Rollout-Generierung an die Kundeninfrastruktur delegiert wird
- Trainer: Führt auf der Grundlage der eingegangenen Rollouts Aktualisierungen des Modellgewichts durch

### Kunden-VPC (z. B. ECS auf EC2):

- Proxy Lambda: Empfängt Rollout-Anfragen und koordiniert sich mit der Kundeninfrastruktur
- Rollout Response SQS: Warteschlange für die Rückgabe abgeschlossener Rollouts an die Trainingsinfrastruktur
- Anfrage generieren SQS: Warteschlange für Anfragen zur Modellgenerierung
- Antwort generieren SQS: Warteschlange für Antworten zur Modellgenerierung



- Kundencontainer: Implementiert eine benutzerdefinierte Orchestrierungslogik (kann das mitgelieferte Starterkit verwenden)
- DynamoDB: Speichert den Status während des Orchestrierungsprozesses und ruft ihn ab

Arbeitsablauf:

1. Rollout delegiert die Rollout-Generierung an Proxy Lambda
2. Proxy Lambda leitet die Rollout-API-Anfrage an Generate Request SQS weiter
3. Der Kundencontainer verarbeitet Anfragen, verwaltet Multi-Turn-Interaktionen und ruft Belohnungsfunktionen auf
4. Der Container speichert den Status nach Bedarf und ruft ihn von DynamoDB ab
5. Container überträgt Rollout-Antworten an Rollout Response SQS
6. Rollout sendet abgeschlossene Rollouts zur Gewichtsaktualisierung an Trainer

## Einrichtung und Ausführung

Detaillierte Anweisungen zur Einrichtung, Rezeptkonfigurationen, Anfrage- und Antwortformate sowie Umgebungsbeispiele finden Sie in der vertraulichen Dokumentation, die Nova Forge-Abonnenten zur Verfügung gestellt wird. Gehen Sie wie folgt vor, um die Nova Forge-Dokumente zu erhalten:

```
aws s3 cp s3://nova-forge-c7363-206080352451-us-east-1/v1/ ./ --recursive
```

Sobald die Assets heruntergeladen wurden, finden Sie die gesamte Dokumentation unter dem docs Ordner.

## Verantwortliches KI-Toolkit und Moderation von Inhalten

### Toolkit für verantwortungsvolle KI

Nova Forge bietet ein Toolkit für verantwortungsvolle KI, das Schulungs- und Bewertungsdaten enthält, um Modelle während des Trainingsprozesses an die Richtlinien für verantwortungsvolle KI von Amazon Nova anzupassen, sowie Laufzeitkontrollen zur Moderation der Modellreaktionen während der Inferenz.

Trainingsdaten — Fälle und Szenarien, in denen verantwortungsvolle KI-Prinzipien, Sicherheitsaspekte und verantwortungsvoller Technologieeinsatz im Vordergrund stehen, stehen für

die Mischung von Daten zur Verfügung, um die Modelle während der weiteren Trainingsvorbereitung verantwortungsbewusst aufeinander abzustimmen.

**Evaluationen** — Evaluationen, in denen die Fähigkeit des Modells getestet wird, unangemessene, schädliche oder falsche Inhalte zu erkennen und abzulehnen, stehen als Benchmark-Aufgabe zur Verfügung, um den Unterschied zwischen der Leistung des Basismodells und der Leistung kundenspezifischer Modelle zu ermitteln.

**Laufzeitkontrollen** — Standardmäßig steuert die Laufzeit von Amazon Nova moderate Modellreaktionen während der Inferenz. Um diese Laufzeitsteuerungen zu ändern, fordern Sie die anpassbaren Einstellungen für die Inhaltsmoderation von Amazon Nova an, indem Sie sich an einen AWS Kundenbetreuer wenden.

Sicherheit liegt in der gemeinsamen Verantwortung der Benutzer AWS und der Benutzer. Eine Änderung des Basismodells oder die kontinuierliche Durchführung von Vorschulungen zur Verbesserung der Leistung in einem bestimmten Anwendungsfall kann sich auf die Sicherheit, Fairness und andere Eigenschaften des neuen Modells auswirken. Eine robuste Anpassungsmethode minimiert Änderungen an den in Basismodellen integrierten Sicherheits-, Fairness- und anderen Schutzmaßnahmen und minimiert gleichzeitig die Auswirkungen auf die Modellleistung bei Aufgaben, für die das Modell nicht maßgeschneidert wurde. End-to-end Das Testen von Anwendungen anhand von Datensätzen, die für Anwendungsfälle repräsentativ sind, ist erforderlich, um festzustellen, ob die Testergebnisse den spezifischen Erwartungen in Bezug auf Sicherheit, Fairness und andere Eigenschaften sowie die Gesamteffektivität entsprechen. Weitere Informationen finden Sie im Amazon Web Services-Leitfaden zur verantwortungsvollen Nutzung von KI, in der Amazon Web Services Services-Richtlinie für verantwortungsvolle KI, in der Amazon Web Services Services-Richtlinie zur akzeptablen Nutzung und in den Nutzungsbedingungen von Amazon Web Services.

## Verfügbarkeit in der Region Nova Forge

Nova Forge ist in den folgenden AWS Regionen verfügbar.

Verfügbarkeit in der Region Nova Forge

| Region                  | Einschränkungen |
|-------------------------|-----------------|
| USA Ost (Nord-Virginia) | Keine           |

| Region            | Einschränkungen                                                                                                                                                                                                                                                                     |
|-------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| USA West (Oregon) | Amazon Bedrock Inference ist in USA West (Oregon) nicht verfügbar. <a href="#">Wir empfehlen, Ihr Modell mithilfe SageMaker von Inferenz bereitzustellen.</a> Alternativ können Sie Ihr Modell mit <a href="#">Amazon Bedrock Model Copy nach USA Ost (Nord-Virginia) kopieren.</a> |

# Verantwortungsvolle Verwendung

Der Aufbau von Sicherheits- und Vertrauensmaßnahmen mit KI-Modellen liegt in der gemeinsamen AWS Verantwortung unserer Kunden. Unser Ziel ist es, unsere Modelle an die [AWS -Richtlinien für die akzeptable Verwendung](#) anzupassen und unerwünschte Ergebnisse zu minimieren, während wir gleichzeitig ein angenehmes Kundenerlebnis bieten. Unser Ansatz für verantwortungsvolle KI (RAI) basiert auf unseren [Kerndimensionen verantwortungsvoller KI](#), welche in der folgenden Liste behandelt werden. Für jede dieser Dimensionen haben wir Richtlinien entwickelt, die unsere Entscheidungsfindung während des gesamten Lebenszyklus der Modellentwicklung bestimmen. Dieser Lebenszyklus umfasst alle Phasen, von der ersten Datenerfassung über die Vortraining bis hin zur Implementierung von Maßnahmen zur Minimierung der Laufzeit nach der Bereitstellung.

- Fairness – Berücksichtigung der Auswirkungen auf verschiedene Interessengruppen
- Erklärbarkeit – Systemausgaben verstehen und bewerten
- Datenschutz und Sicherheit — Angemessene Beschaffung, Nutzung und Schutz von Daten und Modellen
- Sicherheit – Verhinderung schädlicher Daten und missbräuchlicher Nutzung
- Steuerbarkeit – Bereitstellung von Mechanismen zur Überwachung und Steuerung des Verhaltens von KI-Systemen
- Genauigkeit und Robustheit – Erzielung korrekter Systemergebnisse, auch bei unerwarteten oder widersprüchlichen Eingaben
- Governance – Einbindung von bewährten Methoden in die KI-Lieferkette, einschließlich Anbietern und Entwicklern
- Transparenz – Interessenvertreter in die Lage versetzen, fundierte Entscheidungen über ihre Interaktion mit einem KI-System zu treffen

## Richtlinien

Zu den Richtlinien, die wir bei der Entwicklung unseres Modells verwenden, gehören unter anderem die Moderation von Inhalten, die Folgendes verherrlichen, erleichtern oder fördern:

- Teilnahme an gefährlichen Aktivitäten, Selbstverletzung oder Verwendung gefährlicher Substanzen.
- Konsum, Missbrauch oder Handel mit kontrollierten Substanzen, Tabak oder Alkohol.

- Körperliche Gewalt oder Blut.
- Material über Kindesmissbrauch oder sexuellen Kindesmissbrauch.
- Tiermissbrauch oder illegaler Tierhandel.
- Fehlinformationen, die Einzelpersonen oder Gruppen als verantwortlich für vorsätzliche Täuschung, die Untergrabung der Glaubwürdigkeit einer Institution in der Öffentlichkeit oder die Gefährdung der menschlichen Gesundheit oder Lebensgrundlage darstellen.
- Malware, bösartige Inhalte oder Inhalte, die Cyberkriminalität fördern.
- Respektlosigkeit, Diskriminierung oder Stereotyp gegenüber einer Einzelperson oder Gruppe.
- Beleidigungen, Obszönitäten, obszöne Gesten, sexuell explizite Sprache, Pornografie, Hasssymbole oder Hassgruppen.
- Vollständige Nacktheit, die außerhalb eines wissenschaftlichen, pädagogischen oder Referenzkontextes liegt.
- Voreingenommenheit gegenüber einer Gruppe aufgrund eines demografischen Merkmals.

## Empfehlungen

Eignung für die Verwendung: Da die Ausgaben von KI-Modellen wahrscheinlichkeitsbasiert sind, kann es vorkommen, dass Amazon Nova ungenaue oder unangemessene Inhalte generiert. Kunden sollten die Ergebnisse im Hinblick auf Genauigkeit und Angemessenheit für ihren Anwendungsfall bewerten, insbesondere, wenn sie Endbenutzern direkt zur Verfügung gestellt werden. Wenn Amazon Nova in Kundenabläufen verwendet wird, die zu Folgeentscheidungen führen, müssen Kunden außerdem die potenziellen Risiken ihres Anwendungsfalls bewerten und angemessene menschliche Aufsicht, Tests und andere anwendungsfallspezifische Schutzmaßnahmen ergreifen, um diese Risiken zu minimieren.

Prompt-Optimierungen: Falls Sie auf eine Moderation durch Amazon Nova stoßen, sollten Sie die verwendeten Prompts im Hinblick auf die oben genannten Richtlinien überprüfen. Die Optimierung der Prompts zur Verringerung der Wahrscheinlichkeit unerwünschter Resultate ist die empfohlene Strategie, um mit Amazon-Nova-Modellen die erwarteten Ergebnisse zu erzielen. Achten Sie darauf, wo die Eingabe von den Benutzern gesteuert wird, einschließlich Pixelinhalten, die sich auf die Leistung des Modells auswirken könnten. Weitere Informationen finden Sie im Abschnitt mit den Richtlinien für Prompts in diesem Benutzerhandbuch.

Datenschutz: Amazon Nova ist verfügbar in Amazon Bedrock. Amazon Bedrock ist ein verwalteter Service und speichert oder überprüft keine Kundenanfragen oder ausgefüllte Kundenanfragen.

Eingabeaufforderungen und Abschlüsse werden niemals zwischen Kunden oder Partnern geteilt. Amazon Bedrock AWS verwendet keine über den Amazon Bedrock Service generierten Eingaben oder Ausgaben zum Trainieren von Amazon Bedrock Modellen, einschließlich Amazon Nova. Weitere Informationen finden Sie in Abschnitt [50.3](#) der AWS Servicebedingungen und in den [häufig gestellten Fragen zum AWS Datenschutz](#). Servicespezifische Datenschutzinformationen finden Sie im Abschnitt Datenschutz und Sicherheit der [Amazon Bedrock FAQs](#) Dokumentation. Amazon Nova ergreift Maßnahmen, um das Ausfüllen von Prompts zu vermeiden, die als Anforderung privater Informationen ausgelegt werden könnten. Wenn ein Benutzer befürchtet, dass seine privaten Daten in eine Amazon-Nova-Vervollständigung aufgenommen wurden, sollte er uns [hier](#) kontaktieren.

**Sicherheit:** Alle Amazon Bedrock Modelle, einschließlich Amazon Nova, sind mit Unternehmenssicherheit ausgestattet, die es Kunden ermöglicht, generative KI-Anwendungen zu entwickeln, die gemeinsame Datensicherheits- und Compliance-Standards wie GDPR und HIPAA unterstützen. Kunden können AWS PrivateLink damit private Verbindungen zwischen maßgeschneiderten Amazon Nova- und lokalen Netzwerken herstellen, ohne dass der Kundenverkehr dem Internet ausgesetzt wird. Kundendaten werden bei der Übertragung und im Ruhezustand immer verschlüsselt, und Kunden können ihre eigenen Schlüssel verwenden, um die Daten zu verschlüsseln, z. B. AWS Key Management Service Kunden können damit AWS Identity and Access Management den Zugriff auf Amazon Bedrock Ressourcen, einschließlich maßgeschneiderter Amazon Nova, sicher kontrollieren. Darüber hinaus Amazon Bedrock bietet es umfassende Überwachungs- und Protokollierungsfunktionen, mit denen die Anforderungen an Kundenmanagement und Audits erfüllt werden können. Amazon CloudWatch kann beispielsweise dabei helfen, Nutzungskennzahlen nachzuverfolgen, die für Prüfungszwecke erforderlich sind, und AWS CloudTrail kann helfen, API-Aktivitäten zu überwachen und Probleme zu beheben, da Amazon Nova in andere AWS Systeme integriert ist. Kunden können sich auch dafür entscheiden, die Metadaten, Eingabeaufforderungen und Vervollständigungen in ihrem eigenen verschlüsselten Amazon Simple Storage Service (Amazon S3) -Bucket zu speichern.

**Geistiges Eigentum:** AWS [bietet unbegrenzten Versicherungsschutz für geistiges Eigentum \(IP\) für Produkte allgemein verfügbarer Amazon Nova-Modelle \(siehe Abschnitt 50.10 der Servicebedingungen\)](#). Dies bedeutet, dass Kunden vor Ansprüchen Dritter geschützt sind, die eine Verletzung oder widerrechtliche Aneignung von geistigem Eigentum (einschließlich Urheberrechtsansprüchen) durch die von diesen Amazon-Nova-Modellen generierten Ergebnisse geltend machen. Zusätzlich schützt unsere standardmäßige IP-Haftungsfreistellung für die Nutzung von Services Kunden vor Ansprüchen Dritter wegen vermeintlicher IP-Verletzungen (einschließlich Urheberrechtsansprüchen) durch die Services (einschließlich Amazon-Nova-Modelle) und die zu deren Training verwendeten Daten.

# Kontingente für Amazon Nova

Ihr AWS-Konto hat Standardkontingente, früher als Limits bezeichnet, für Amazon Bedrock. Führen Sie einen der folgenden Schritte aus, um Service Quotas für Amazon Bedrock anzuzeigen:

- Folgen Sie den Schritten unter [Service Quotas anzeigen](#) und wählen Sie Amazon Bedrock als Service aus.
- Weitere Informationen zu [Amazon Bedrock-Endpunkten und -Kontingenten](#) finden Sie in der Allgemeine AWS-Referenz

## Note

Wenn ein Kontingent über Servicekontingente als nicht anpassbar gekennzeichnet ist, können Sie über das [Formular zur Erhöhung des Limits](#) eine Anfrage einreichen, um für eine Erhöhung in Betracht gezogen zu werden.

Um die Leistung des Service aufrechtzuerhalten und eine angemessene Nutzung von Amazon Bedrock sicherzustellen, können die einem Konto zugewiesenen Standardkontingente je nach regionalen Faktoren, Zahlungsverlauf, betrügerischer Nutzung und and/or Genehmigung einer Anfrage zur Erhöhung des Kontingents aktualisiert werden.

## Eine Erhöhung der Amazon-Nova-Kontingente beantragen

Sie können eine Kontingenterhöhung für Ihr Konto anfordern, indem Sie die folgenden Schritte ausführen:

- Wenn ein Kontingent in der Spalte Anpassbar in [Amazon Bedrock Endpoints und Kontingente](#) in der als Ja markiert ist Allgemeine AWS-Referenz, können Sie es anpassen, indem Sie die Schritte unter [Anfrage einer Kontingenterhöhung](#) im Service Quota-Benutzerhandbuch im [Service Quotas User](#) Guide befolgen.
- Die Aufrufkontingente des On-Demand-Modells in [Amazon Bedrock-Endpunkten und die Kontingente](#) in den können Allgemeine AWS-Referenz nicht über Service Quotas angepasst werden. Wenden Sie sich an Ihren AWS-Konto Manager, um eine Erhöhung in Betracht zu ziehen.

 Note

Aufgrund der hohen Nachfrage werden Kunden bevorzugt behandelt, deren Datenverkehr das ihnen zugewiesene Kontingent überschreitet. Ihre Anfrage wird möglicherweise abgelehnt, wenn Sie diese Bedingung nicht erfüllen.

- Sie können über das [Formular zur Erhöhung des Limits](#) einen Antrag auf Erhöhung stellen, auch wenn in den [Amazon-Bedrock-Endpunkten und -kontingenten](#) in der Allgemeine AWS-Referenz in der Spalte Anpassbar ein Kontingent mit Nein gekennzeichnet ist,



# Überwachen von Amazon Nova

Die Überwachung ist ein wichtiger Bestandteil der Aufrechterhaltung der Zuverlässigkeit, Verfügbarkeit und Leistung von Amazon Nova und Ihren anderen AWS Lösungen. AWS bietet die folgenden Überwachungstools, um Amazon Nova zu beobachten, zu melden, wenn etwas nicht stimmt, und gegebenenfalls automatische Maßnahmen zu ergreifen:

Da Amazon Nova über Amazon Bedrock verfügbar ist, befolgen Sie alle Überwachungsanweisungen unter [Zustand und Leistung von Amazon Bedrock überwachen](#).

# Sicherheit in Amazon Nova

Cloud-Sicherheit AWS hat höchste Priorität. Als AWS Kunde profitieren Sie von Rechenzentren und Netzwerkarchitekturen, die darauf ausgelegt sind, die Anforderungen der sicherheitssensibelsten Unternehmen zu erfüllen.

Sicherheit ist eine gemeinsame AWS Verantwortung von Ihnen und Ihnen. Das [Modell der geteilten Verantwortung](#) beschreibt dies als Sicherheit der Cloud und Sicherheit in der Cloud:

- Sicherheit der Cloud — AWS ist verantwortlich für den Schutz der Infrastruktur, auf der AWS Dienste in der ausgeführt AWS Cloud werden. AWS bietet Ihnen auch Dienste, die Sie sicher nutzen können. Third-party Prüfer testen und verifizieren regelmäßig die Wirksamkeit unserer Sicherheitsmaßnahmen im Rahmen der [AWS](#). Weitere Informationen zu den Compliance-Programmen, die für Amazon Nova gelten, finden Sie unter [AWS Services im Bereich nach Compliance-Programm AWS](#).
- Sicherheit in der Cloud — Ihre Verantwortung richtet sich nach dem AWS Service, den Sie nutzen. Sie sind auch für andere Faktoren verantwortlich, darunter die Sensibilität Ihrer Daten, die Anforderungen Ihres Unternehmens und die geltenden Gesetze und Vorschriften.

Da Amazon Nova über Amazon Bedrock verfügbar ist, beachten Sie bitte alle Sicherheitshinweise unter [Sicherheit in Amazon Bedrock](#).

# Erstellen Sie Amazon Nova-Ressourcen mit AWS CloudFormation

Wenn Sie Amazon Nova-Modelle über Amazon Bedrock mit bereitstellen CloudFormation, befolgen Sie alle CloudFormation Hinweise unter [Amazon Bedrock-Ressourcen erstellen](#) mit. CloudFormation

Weitere Informationen, einschließlich Beispiele für JSON- und YAML-Vorlagen, finden Sie in der Datei [YOUR-SERVICE-RESOURCE-TOPNODE-IN-CLOUDFORMATION](#). Ändern Sie diesen Link in der Datei local-phrases.ent im Benutzerhandbuch. YOUR-RESOURCE-PLURAL AWS CloudFormation

## Erfahren Sie mehr über CloudFormation

Weitere Informationen CloudFormation dazu finden Sie in den folgenden Ressourcen:

- [AWS CloudFormation](#)
- [AWS CloudFormation Benutzerhandbuch](#)
- [CloudFormation API Referenz](#)
- [AWS CloudFormation Benutzerhandbuch für die Befehlszeilenschnittstelle](#)

# Dokumentenverlauf für den Amazon Nova Developer Guide

In der folgenden Tabelle werden die Dokumentationsversionen für Amazon Nova 2.0 beschrieben.

| Änderung                                          | Beschreibung                                                                                                                                                                                                                                                        | Datum            |
|---------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------|
| <a href="#">Erste Version von Amazon Nova 2.0</a> | Erste Veröffentlichung des Amazon Nova 2.0 Developer Guide mit neuen Modellen: Nova 2 Lite, Amazon Nova Sonic und. In diesem Leitfaden werden erweiterte multimodale Funktionen, Argumentationsmerkmale und verbesserte Leistung in allen Modellstufen vorgestellt. | 2. Dezember 2025 |

Die vorliegende Übersetzung wurde maschinell erstellt. Im Falle eines Konflikts oder eines Widerspruchs zwischen dieser übersetzten Fassung und der englischen Fassung (einschließlich infolge von Verzögerungen bei der Übersetzung) ist die englische Fassung maßgeblich.