



Guida per sviluppatori per Amazon Nova 2

Amazon Nova



Amazon Nova: Guida per sviluppatori per Amazon Nova 2

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

I marchi e l'immagine commerciale di Amazon non possono essere utilizzati in relazione a prodotti o servizi che non siano di Amazon, in una qualsiasi modalità che possa causare confusione tra i clienti o in una qualsiasi modalità che denigri o discrediti Amazon. Tutti gli altri marchi non di proprietà di Amazon sono di proprietà dei rispettivi proprietari, che possono o meno essere affiliati, collegati o sponsorizzati da Amazon.

Table of Contents

Cos'è Amazon Nova 2?	1
Concetti chiave	1
Modelli Amazon Nova	1
Cosa puoi costruire?	2
Vantaggi	3
Come funziona Amazon Nova	3
Prezzi	4
Fasi successive	4
Novità di Amazon Nova 2	5
Nuovi modelli	5
Nuove caratteristiche e funzionalità	5
Incorporamenti multimodali Nova	5
Pensiero e ragionamento estesi	5
Strumenti integrati	6
Costruzione di agenti AI	6
Migliore comprensione dei documenti	6
Comprensione video migliorata	6
Personalizzazione del modello	6
Amazon Nova Forge	7
Fasi successive	7
Nozioni di base	8
Nozioni di base sulla console	8
Esplorazione del playground di testo	9
Nozioni di base sull'API	9
Ottenere le credenziali per concedere l'accesso programmatico	11
Collegare autorizzazioni Amazon Bedrock a un utente o a un ruolo	12
Generare una risposta per un prompt di testo utilizzando un modello Amazon Nova	13
Inferenza di base	14
Importante: configurazione del timeout	15
Argomenti di inferenza principali	15
Utilizzo dell'API Converse	16
Struttura delle richieste	16
Utilizzo delle istruzioni di sistema	17
Parametri di inferenza	18

Usare il ragionamento	19
Utilizzo dell'API Invoke	21
Struttura della richiesta	22
Parametri della richiesta	23
Streaming delle risposte	23
Streaming con ConverseStream	23
Streaming con InvokeModelWithResponseStream	24
Tipi di eventi in streaming	24
Utilizzo degli incorporamenti Amazon Nova	25
Funzionalità principali	25
Generazione di incorporamenti	26
Inferenza on demand	29
Vantaggi	30
Utilizzo dell'inferenza su richiesta	30
Prezzi	30
Quote e limiti	31
Utilizzo delle funzionalità Nova	32
Ragionamento	32
Comprensione multimodale	33
Tipo di contenuto supportato per modalità	33
Comprensione delle immagini	34
Comprensione dei video	36
Comprensione dei documenti	39
Da voce a voce	42
Funzionalità principali	42
Nozioni di base	43
Indica le importazioni e la configurazione	43
Definisci la classe SimpleNovaSonic	44
Inizializza il client	45
Gestione degli eventi	45
Avvia la sessione	45
Gestione dell'input audio	48
Termina la sessione	50
Gestione delle risposte	50
Riproduzione audio	52
Acquisizione audio	53

Esecuzione della funzione principale	54
Esempi di codice	55
Esempi di nozioni di base	55
Casi d'uso avanzati	56
Workshop pratico	57
Istruzioni per le conversazioni vocali	57
Linee guida importanti	57
Prompt di sistema di base consigliato per la voce	58
Configurazione del prompt vocale	58
Configurazione del prompt di sistema	59
Accordo di genere per le lingue di genere	60
Catena di pensiero per il discorso: ragionamento costituzionale	61
Uso eccessivo delle frasi suggerite	62
Concetti principali	64
Ciclo di vita dell'evento	64
Sequenza del flusso di eventi	66
Gestione degli eventi di input con l'API bidirezionale	66
Gestione degli eventi di output con l'API bidirezionale	75
Barge-in	82
Controllabilità a turni	84
Ingresso intermodale	85
Supporto linguistico e funzionalità multilingue	88
Gestione della cronologia chat	90
Configurazione dello strumento	95
Chiamata asincrona degli strumenti	103
Integrazioni	106
Agenti Strands	106
Integrazioni del framework	109
Sistemi avanzati con Nova	120
Panoramica di	120
Pensiero esteso	120
Come funziona il pensiero esteso	120
Opzioni di configurazione	123
Modelli supportati	124
Pensiero esteso con uso di strumenti	124
Comprensione dei token di ragionamento e dei prezzi	124

Domande frequenti	125
Utilizzo degli strumenti	126
Comprendere il flusso di lavoro relativo all'utilizzo degli strumenti	126
Crea uno strumento	126
Chiamate uno strumento	129
Strumenti di sistema integrati	133
Creazione di agenti IA	136
Creazione di un agente	136
Invocazione di un agente	138
Web grounding	141
Come funziona il web grounding	141
Come usare il web grounding	141
Disponibilità regionale	142
Struttura della risposta	142
Sicurezza di messa a terra	143
Gestione degli errori	144
Autorizzazioni necessarie per gli strumenti integrati	144
Progettazione di prompt	146
Che cos'è l'ingegneria tempestiva	146
Iniziare con la progettazione tempestiva	146
Best practice	147
Comprensione dei ruoli	147
Crea istruzioni precise	148
Concentrare l'attenzione su sezioni del prompt	167
Utilizzo del ruolo di sistema	168
Fornire esempi (few-shot prompting)	176
Sistemi di chiamata degli strumenti	186
Tecniche di suggerimento avanzate	188
Richiesta di input multimodali	209
Linee guida multimodali generali	210
Comprensione di documenti e immagini	211
Comprensione dei video	36
Moderazione dei contenuti	222
Principi chiave	222
Configurazione consigliata	223
MLCommons tassonomia universale	223

Esempi di suggerimenti	225
Codice e risoluzione dei problemi	231
Libreria di codici	231
Esempi di API Converse	231
InvokeModel Esempi di API	251
Risoluzione dei problemi	256
Autenticazione e configurazione	256
Accesso al modello negato	257
Problemi di disponibilità a livello regionale	257
Configurazione del timeout	257
Problemi di risposta delle API	258
Errori in modalità ragionamento	259
Problemi di utilizzo degli strumenti	260
Riferimento per API e SDK	264
Schema di richiesta e risposta	264
Struttura completa delle richieste	264
Struttura di risposta completa	269
Riferimento SDK	272
Personalizzazione del modello Amazon Nova	274
Approcci di personalizzazione	274
Piattaforme di personalizzazione	275
Prerequisiti generali	276
Ricette Amazon Nova	277
Recupero di ricette di base	278
Ottenere le ricette di Forge	279
Modelli e algoritmi disponibili	279
Amazon Nova 2.0 Lite	280
Sui lavori SageMaker di formazione	287
Best practice per la personalizzazione di Amazon Nova	288
SDK Nova Forge	293
Addestramento	299
Monitoraggio dei progressi tra le iterazioni	335
Valutazione	340
Addestramento iterativo	407
Su SageMaker HyperPod	408
Requisiti di calcolo per i modelli Amazon Nova 2	408

Best practice per la personalizzazione di Amazon Nova	288
SDK Nova Forge	415
Configurazione del cluster HP	415
Guida ai comandi essenziali	415
Accesso e configurazione di Nova Forge	426
Addestramento	427
Valutazione	468
MLflow monitoraggio	520
Formazione iterativa	522
Panoramica di	522
Come funziona	523
Quando utilizzare la formazione iterativa	524
Esempio di flusso di lavoro: SFT → RFT	525
Monitoraggio dei progressi tra le iterazioni	527
Best practice	529
Considerazioni sui costi	531
Limitazioni	532
Risoluzione dei problemi	533
SageMaker Inferenza	534
Funzionalità	535
Modelli e istanze supportati	536
Regioni supportate AWS	538
Immagini dei container supportate	538
Best practice	539
Supporto	539
Nozioni di base	539
Guida di riferimento alle API	561
Valuta i modelli	570
Rilevamento degli abusi per Amazon Nova Forge	577
Inferenza di Amazon Bedrock	578
Implementare un modello personalizzato per l'inferenza on demand	579
Inferenza on demand	584
Limitazioni	586
Nova Forge	588
Prerequisiti	588
Iscriviti a Nova Forge	588

Altri prerequisiti	589
Accesso e configurazione di Nova Forge	589
Ottenere i documenti di Nova Forge	589
Fase 1: Abbonarsi a Nova Forge	590
Passaggio 2. Configura l'infrastruttura HyperPod	596
Impostazioni di moderazione dei contenuti	596
Pre-allenamento continuo e a metà allenamento	597
Cosa sono i checkpoint intermedi e perché sono necessari?	597
Quali posti di blocco sono disponibili?	598
Quale checkpoint usare?	599
Come utilizzare il mixaggio dei dati per Nova 2.0?	600
Analisi delle categorie di miscelazione dei dati	601
Ottimizzazione di precisione supervisionata	606
Introduzione	606
Quando usare SFT?	606
Quando utilizzare i parametri in modo efficiente e quando utilizzare SFT a livello completo?	607
Miscelazione dei dati per SFT	608
Esempi di configurazione YAML	609
Checkpoints modello	611
Approcci formativi	611
Prerequisiti prima di iniziare	612
Un approccio sistematico per ottenere un SFT di successo	613
Sequenziamento degli esperimenti e miscelazione dei dati	614
Preparare il set di dati per SFT	614
Metodi di valutazione	615
Best practice	288
Preparare Training Job Config	617
Configura Data Mixing Block	618
Come avviare un lavoro	624
Come monitorare Job	633
Come valutare il modello dopo SFT?	635
Lezioni apprese e suggerimenti	638
Apprendimento per rinforzo	638
Porta il tuo orchestratore personale per valutazioni agentiche a più turni	639
Toolkit AI responsabile	640

Toolkit di intelligenza artificiale responsabile	640
Uso responsabile	642
Linee guida	642
Raccomandazioni	643
Quote	645
Richiedi un aumento delle quote di Amazon Nova	645
Monitoraggio	647
Sicurezza	648
Creare risorse con CloudFormation	649
Scopri di più su CloudFormation	649
Cronologia dei documenti	650
.....	dcli

Cos'è Amazon Nova 2?

Amazon Nova fornisce modelli di base multimodali che elaborano testo, immagini, video, documenti e voce. Con il supporto per un massimo di 1 milione di token di contesto e funzionalità di ragionamento avanzate, i modelli Amazon Nova 2 ti consentono di creare applicazioni AI sofisticate che comprendono input complessi e generano risposte accurate.

Puoi creare chatbot interattivi, analizzare documenti e video, creare agenti di intelligenza artificiale con ragionamento esteso e sviluppare applicazioni vocali.

Concetti chiave

Prima di conoscere i modelli Amazon Nova, acquisisci familiarità con i seguenti concetti fondamentali:

Modelli Foundation

Sistemi di intelligenza artificiale preaddestrati disponibili in diverse dimensioni e funzionalità a cui è possibile accedere tramite un'API.

Inferenza

Il processo di invio di una richiesta a un modello e ricezione di una risposta generata.

Ragionamento

Capacità di pensiero estesa che consente ai modelli di scomporre problemi complessi e di mostrarne step-by-step l'analisi prima di fornire risposte.

Multimodale

La capacità di elaborare e comprendere contemporaneamente più tipi di input: testo, immagini, video e documenti in un'unica richiesta.

RAG (Retrieval-Augmented Generation)

Una tecnica che combina le risposte dei modelli con le proprie fonti di dati per fornire risposte più accurate e contestuali.

Modelli Amazon Nova

Amazon Nova 2 include i seguenti modelli, ciascuno ottimizzato per diversi casi d'uso:

Modello	Modalità di input	Modalità di output	Casi d'uso
Nova 2 Lite	Testo, immagini, video, documenti	Testo	Applicazioni ad alto volume che danno priorità alla velocità e all'efficienza dei costi
Nova 2 Sonic	Discorso, testo	Discorso, testo	Applicazioni vocali con tempi di risposta rapidi
Incorporamenti multimodali Nova	Testo, immagini, documenti, video, audio	Embedding	Ricerca semantica, sistemi di raccomandazione e corrispondenza per somiglianza

Tutti i modelli supportano fino a 1 milione di token di contesto e possono generare fino a 65.536 token in una singola risposta. I modelli con capacità di ragionamento possono eseguire riflessioni approfondite per risolvere problemi complessi passo dopo passo.

Cosa puoi costruire?

Di seguito sono riportati alcuni esempi di ciò che puoi creare con Amazon Nova:

- Assistente documentale intelligente: elabora documenti di grandi dimensioni con un massimo di 1 milione di token di contesto per rispondere a domande ed estrarre informazioni (con RAG)
- Applicazioni di ragionamento complesse: risolvi problemi in più fasi con un pensiero esteso che mostri l' step-by-step analisi del modello (o con il ragionamento)
- Pipeline di analisi video: estrai informazioni dettagliate, genera riepiloghi e identifica i momenti chiave dei contenuti video su larga scala (Nova 2 Lite)
- Agente di intelligenza artificiale con funzionalità vocale: crea agenti conversazionali in grado di comprendere l'input vocale e rispondere con il linguaggio naturale (Nova 2 Sonic)

Vantaggi

Amazon Nova offre i seguenti vantaggi:

Comprensione multimodale

Elabora testo, immagini, video, documenti e voce in un'unica richiesta. I modelli Amazon Nova comprendono le relazioni tra diversi tipi di input.

Contesto esteso

Il supporto per un massimo di 1 milione di token consente di elaborare intere basi di codice, documenti lunghi o conversazioni estese senza perdere il contesto.

Ragionamento avanzato

I modelli con funzionalità di ragionamento risolvono problemi complessi e mostrano step-by-step analisi, migliorando la precisione per le attività in più fasi.

Implementazione flessibile

Accedi ai modelli tramite Amazon Bedrock senza alcuna infrastruttura da gestire o personalizza i modelli tramite la messa a punto e l'apprendimento per rinforzo.

Strumenti integrati

Usa il web grounding per accedere a informazioni in tempo reale e interprete di codice per eseguire codice Python senza integrazioni esterne.

Come funziona Amazon Nova

I modelli Amazon Nova sono modelli base a cui puoi accedere tramite Amazon Bedrock. Il flusso di lavoro di base è:

1. L'applicazione invia una richiesta ad Amazon Bedrock con i parametri di input e configurazione.
2. Il modello Amazon Nova elabora i tuoi input, applicando il ragionamento se configurato.
3. Il modello genera una risposta e la restituisce all'applicazione.

Puoi migliorare le risposte utilizzando RAG per incorporare i tuoi dati, abilitando strumenti integrati o personalizzando i modelli tramite la messa a punto.

Prezzi

I prezzi di Amazon Nova si basano sui token di input e output elaborati. Modelli diversi hanno livelli di prezzo diversi:

- Nova 2 Lite: ottimizzato per un'elaborazione economica e ad alto volume
- Nova 2 Sonic: prezzi bilanciati per le applicazioni con funzionalità vocali

Per informazioni aggiornate sui prezzi, consulta la pagina dei [prezzi di Amazon Bedrock](#).

Fasi successive

- Per ulteriori informazioni sulle nuove funzionalità di Amazon Nova 2, consulta [Novità di Amazon Nova 2](#).
- Per iniziare a usare Amazon Nova, consulta [Guida introduttiva ad Amazon Nova 2](#).
- Per ulteriori informazioni sulle funzionalità di inferenza di base, consulta [Inferenza di base](#).
- Per personalizzare i modelli per il tuo caso d'uso, consulta [Personalizzazione dei modelli Amazon Nova sull'intelligenza artificiale SageMaker](#).

Novità di Amazon Nova 2

Amazon Nova 2 introduce miglioramenti significativi in termini di capacità di comprensione, creatività e riconoscimento vocale. Le seguenti sezioni descrivono le nuove funzionalità e i miglioramenti principali.

Nuovi modelli

Nova 2 Lite

Modelli avanzati che offrono un ragionamento avanzato con supporto di pensiero esteso, controllo dell'intensità a tre livelli e comprensione multimodale ottimizzati per flussi di lavoro agentici su scala di produzione.

Nova 2 Sonic

Un modello di conversazione vocale aggiornato con funzionalità migliorate di comprensione del parlato, elaborazione del linguaggio naturale e generazione della voce in sette lingue.

Incorporamenti multimodali Nova

Un modello di incorporamento multimodale che elabora input di testo, immagini, documenti, video e audio e genera incorporamenti.

Nuove caratteristiche e funzionalità

Incorporamenti multimodali Nova

Nova Multimodal Embeddings supporta testo, documenti, immagini, video e audio attraverso un unico modello, abilitando applicazioni di recupero intermodali. Nova Multimodal Embeddings mappa ciascuno di questi tipi di contenuto in uno spazio semantico unificato, consentendovi di condurre operazioni vettoriali unimodali, intermodali e multimodali, alimentando applicazioni come la generazione aumentata di recupero agentico (RAG) e la ricerca semantica multimodale.

Pensiero e ragionamento estesi

Nova 2 Lite supporta il pensiero esteso, che consente ai modelli di dedicare più tempo al ragionamento su problemi complessi prima di generare risposte. Questa funzionalità migliora la

precisione per le attività di ragionamento in più fasi, inclusi flussi di lavoro agentici con più strumenti, matematica avanzata, pianificazione complessa e generazione di codice.

Per ulteriori informazioni, accedi a [Pensiero esteso in Amazon Nova 2](#)

Strumenti integrati

Amazon Nova 2 include strumenti integrati che estendono le funzionalità del modello senza richiedere integrazioni esterne:

- Web Grounding: accede alle informazioni in tempo reale dal Web per fornire up-to-date risposte e ridurre le allucinazioni.
- Interprete di codice: esegue codice Python per eseguire calcoli.

Costruzione di agenti AI

I modelli Amazon Nova 2 sono ottimizzati per la creazione di agenti AI. I modelli offrono un migliore utilizzo degli strumenti, un migliore ragionamento per le attività in più fasi e una maggiore capacità di mantenere il contesto in flussi di lavoro complessi tra agenti.

Migliore comprensione dei documenti

Nova 2 Lite offre funzionalità avanzate di elaborazione dei documenti con una migliore comprensione di layout di documenti complessi, tabelle, grafici e documenti multipagina. I modelli estraggono le informazioni in modo più accurato da fogli di calcolo PDFs e altri formati di documenti.

Comprensione video migliorata

Nova 2 Lite offre funzionalità di analisi video migliorate, tra cui una migliore percezione visiva, comprensione temporale, riconoscimento delle azioni e la capacità di elaborare sequenze video più lunghe con maggiore precisione.

Personalizzazione del modello

Nova 2 Lite supporta il fine-tuning supervisionato (SFT) e il reinforcement fine-tuning (RFT) su Amazon Bedrock e SageMaker AI, consentendoti di adattare Amazon Nova 2 alle tue esigenze aziendali specifiche.

Amazon Nova Forge

Amazon Nova Forge è un first-of-its-kind servizio che offre alle organizzazioni il modo più semplice ed economico per creare i propri modelli di frontiera utilizzando Amazon Nova.

Fasi successive

- Per ulteriori informazioni sui modelli e le funzionalità di Amazon Nova, consulta [Cos'è Amazon Nova 2?](#).
- Per iniziare a usare Amazon Nova 2.0, consulta [Guida introduttiva ad Amazon Nova 2](#).
- Per esplorare le funzionalità di inferenza di base, consulta [Inferenza di base](#).

Guida introduttiva ad Amazon Nova 2

Puoi richiamare i modelli Amazon Nova 2 con i seguenti metodi:

- Operazioni delle API Amazon Bedrock [InvokeModelo](#) [Converse](#)
- [Parchi giochi Amazon Bedrock Chat e SMS](#) per Nova 2 Lite, Nova 2 Sonic

Important

Se sei nuovo utente AWS o utilizzi Amazon Bedrock, devi prima configurare Amazon Bedrock seguendo la procedura descritta nella [Guida introduttiva ad Amazon Bedrock](#). [In alternativa, puoi provare i modelli Amazon Nova senza accedere ad Amazon Bedrock all'indirizzo `nova.amazon.com` o iniziare a creare gratuitamente su `nova.amazon.com/dev`.](#)

Seleziona un argomento per iniziare a utilizzare Amazon Nova con tale metodo.

Nozioni di base su Amazon Nova nella console Amazon Bedrock

Questa sezione descrive come utilizzare i campi di gioco della AWS console per inviare un messaggio di testo ai modelli Amazon Nova 2 e generare una risposta con testo o immagine. Prima di eseguire i seguenti esempi, devi verificare di aver soddisfatto i seguenti prerequisiti:

Prerequisiti

- Hai un AWS account e disponi delle autorizzazioni per accedere a un ruolo in quell'account con le autorizzazioni necessarie per Amazon Bedrock. In caso contrario, segui la procedura indicata alla pagina [Getting started with Amazon Bedrock](#).
- Se accedi al modello da una regione degli Stati Uniti, devi utilizzare l'endpoint CRIS statunitense, che prevede l'aggiunta del `us` prefisso all'ID del modello (ad esempio). `us.amazon.nova-2-lite-v1:0`
- Se si accede al modello dall'esterno degli Stati Uniti, è possibile utilizzare l'endpoint CRIS globale (ad esempio `global.amazon.nova-2-lite-v1:0`) o inserire come prefisso la regione nell'ID del modello (ad esempio `eu.jp`).

Esplorazione del playground di testo

Nell'esempio seguente viene illustrato come utilizzare il playground di testo:

1. Apri la console Amazon Bedrock all'indirizzo <https://console.aws.amazon.com/bedrock/>.
2. Dal riquadro di navigazione a sinistra, scegli Chat/Testo in Playground.
3. Scegli Seleziona modello e seleziona un provider e un modello. Per questo esempio, seleziona Amazon, quindi seleziona un modello Amazon Nova 2 (come Nova 2 Lite o Nova 2 Sonic). Quindi, scegliere Apply (Applica).
4. Seleziona un prompt predefinito sotto il pannello di testo oppure inserisci un prompt nel pannello di testo, ad esempio **Describe the purpose of a "hello world" program in one line.**
5. Per esplorare le funzionalità di comprensione delle immagini di Amazon Nova, puoi caricare un'immagine in formato JPEG, PNG, GIF o WEBP di dimensioni inferiori o uguali a 25 MB dal computer. Dopo averla caricata, puoi chiedere informazioni sull'immagine ad Amazon Nova.
6. Per esplorare le funzionalità di comprensione dei documenti di Amazon Nova, puoi caricare documenti in formato CSV, DOC, DOCX, HTML, MD, PDF, TXT, XLS o XLSX di dimensioni inferiori o uguali a 4,5 MB. Dopo averli caricati, puoi chiedere informazioni sui documenti ad Amazon Nova.
7. Per esplorare le funzionalità di comprensione video di Amazon Nova, puoi caricare un video in MKV, MOV o MP4 formato inferiore o uguale a 25 MB dal tuo computer. Per i video fino a 1 GB puoi utilizzare Amazon S3. Dopo averlo caricato, puoi chiedere informazioni sul video ad Amazon Nova.
8. Scegli Esegui per eseguire l'inferenza sul modello. Il testo generato viene visualizzato sotto il prompt nel pannello di testo.

Nozioni di base sull'API

Prima di iniziare APIs, segui queste procedure se non conosci AWS o devi installare la AWS CLI o un AWS SDK. Se nessuna di queste condizioni si applica al tuo caso, passa a. [Ottenere le credenziali per concedere l'accesso programmatico](#)

Sono nuovo AWS

Se non disponi di un AWS account, completa i seguenti passaggi per crearne uno. In alternativa, puoi iniziare a creare gratuitamente con Amazon Nova all'indirizzo nova.amazon.com/dev.

Per creare un account AWS

1. Apri la <https://portal.aws.amazon.com/billing/registrazione>.
2. Segui le istruzioni online.

Nel corso della procedura di registrazione riceverai una telefonata o un messaggio di testo e ti verrà chiesto di inserire un codice di verifica attraverso la tastiera del telefono.

Quando si registra un AWS account, viene creato un utente root dell'AWS account. L'utente root ha accesso a tutte le risorse e i servizi AWS in tale account. Come procedura consigliata in materia di sicurezza, assegna l'accesso amministrativo a un utente e utilizza solo l'utente root per eseguire [attività che richiedono l'accesso da parte dell'utente root](#).

AWS ti invia un'e-mail di conferma dopo il completamento della procedura di registrazione. In qualsiasi momento, puoi visualizzare l'attività corrente del tuo account e gestirlo accedendo a <https://aws.amazon.com/> e scegliendo Il mio account.

Proteggi il tuo AWS account (utente root).

1. Accedi [Console di gestione AWS](#) come proprietario dell'account scegliendo Utente root e inserendo l'indirizzo email AWS del tuo account. Nella pagina successiva, inserisci la password.

Per informazioni sull'accesso tramite utente root, consulta [Accesso come utente root nella Guida per l'utente di AWS accesso](#).

2. Abilita l'autenticazione a più fattori (MFA) per l'utente root.

Per istruzioni, consulta [Abilitare un dispositivo MFA virtuale per l'utente root \(console\) dell' AWS account](#) nella Guida per l'utente IAM.

Devo installare la AWS CLI o un SDK AWS

Per installare la AWS CLI, segui i passaggi in [Installa o aggiorna alla versione più recente della AWS CLI](#).

Per installare un AWS SDK, seleziona la scheda corrispondente al linguaggio di programmazione che desideri utilizzare in [Tools to Build on](#). AWS

AWS i kit di sviluppo software (SDKs) sono disponibili per molti linguaggi di programmazione più diffusi. Ogni SDK fornisce un'API, esempi di codice e documentazione che semplificano agli

sviluppatori la creazione di applicazioni nella loro lingua preferita. SDKs esegue automaticamente attività utili per te, come:

- Firma crittografata delle richieste di servizio
- Richieste di ripetizione
- Gestione delle risposte di errore

Ottenere le credenziali per concedere l'accesso programmatico

Gli utenti necessitano dell'accesso programmatico se desiderano interagire con l' AWS esterno della console di AWS gestione. Il modo per concedere l'accesso programmatico dipende dal tipo di utente che accede. AWS

Per fornire agli utenti l'accesso programmatico, scegli una delle seguenti opzioni.

Quale principal e necessita dell'accesso programmatico?	Per	Come
Utenti IAM	Limita la durata delle credenziali a lungo termine per firmare le richieste programmatiche alla AWS CLI, oppure. AWS SDKs AWS APIs	Segui le istruzioni per l'interfaccia che desideri utilizzare. • Per la AWS CLI, consulta Autenticazione tramite credenziali utente IAM nella AWS Command Line Interface User Guide. • Per gli strumenti AWS SDKs e gli strumenti, consulta Autenticazione tramite credenziali a lungo termine nella Guida di riferimento agli strumenti e agli strumenti.AWS SDKs • Per AWS APIs, consulta la sezione Gestione delle chiavi di accesso

Quale principal e necessita dell'accesso programmatico?	Per	Come
		per gli utenti IAM nella Guida per l'utente IAM.
Ruoli IAM	Utilizza credenziali temporanee per firmare le richieste programmatiche alla AWS CLI, oppure. AWS SDKs AWS APIs	Segui le istruzioni in Utilizzo di credenziali temporanee con AWS risorse nella Guida per l'utente IAM.
Utenti gestiti in IAM Identity Center	Utilizza credenziali temporanee per firmare le richieste programmatiche alla AWS CLI, oppure. AWS SDKs AWS APIs	Segui le istruzioni per l'interfaccia che desideri utilizzare. • Per la AWS CLI, consulta Configurazione della AWS CLI per l'utilizzo di IAM Identity Center nella AWS Command Line Interface User Guide. • Per gli strumenti e AWS SDKs AWS APIs, consulta l'autenticazione di IAM Identity Center nella Guida di riferimento AWS SDKs and Tools.

Collegare autorizzazioni Amazon Bedrock a un utente o a un ruolo

Dopo aver impostato le credenziali per l'accesso programmatico, devi configurare le autorizzazioni per un utente o un ruolo IAM per avere accesso alle azioni relative ad Amazon Bedrock. Per configurare queste autorizzazioni, procedi come segue:

1. Nella home page della console di AWS gestione, seleziona il servizio IAM o accedi alla console IAM all'indirizzo. <https://console.aws.amazon.com/iam/>
2. Seleziona Utenti o Ruoli, poi seleziona l'utente o il ruolo desiderato.

3. Nella scheda Autorizzazioni, scegli Aggiungi autorizzazioni, quindi scegli Aggiungi policy AWS gestita. Scegli la policy gestita [AmazonBedrockFullAccess](#) AWS .
4. Per consentire all'utente o al ruolo di abbonarsi ai modelli, scegli Crea policy inline, poi specifica le seguenti autorizzazioni nell'editor JSON:

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

Generare una risposta per un prompt di testo utilizzando un modello Amazon Nova

[Dopo aver soddisfatto tutti i prerequisiti, puoi provare a effettuare richieste di invocazione di modelli su modelli Amazon Nova con una richiesta Converse.](#)

Per installare la AWS CLI, segui i passaggi in [Installa o aggiorna alla versione più recente della AWS CLI](#). Verifica di aver configurato le credenziali per utilizzare Boto3 seguendo la procedura indicata alla pagina [Ottenere le credenziali per concedere l'accesso programmatico](#).

Per generare una risposta per un prompt di testo in Nova 2 Lite utilizzando la AWS CLI, esegui il seguente comando in un terminale:

```
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"}}'
```

Inferenza di base

L'inferenza è il processo di invio di una richiesta a un modello Amazon Nova e di ricezione di una risposta generata. I modelli Amazon Nova supportano l'inferenza tramite due opzioni API:

- Converse API ([Converse](#), [ConverseStream](#)): fornisce un'interfaccia coerente tra diversi modelli, semplificando il passaggio da un modello all'altro o la creazione di applicazioni che funzionano con più modelli. Consigliata per la maggior parte dei casi d'uso.
- Invoke API ([InvokeModel](#), [InvokeModelWithResponseStream](#)): i payload delle richieste sono strutturati specificamente per il formato nativo di ogni modello. Esegue l'inferenza utilizzando i parametri di prompt e inferenza forniti nel corpo della richiesta.

Entrambi APIs supportano le stesse funzionalità principali, tra cui:

- Conversazioni a più turni
- Ingressi multimodali (testo, immagini, video, audio)
- Utilizzo degli strumenti
- Guardrail
- Streaming delle risposte

La struttura della richiesta è quasi identica tra le due APIs, differisce solo per il modo in cui vengono codificati i dati in byte (documenti, immagini, video e audio). Per i parametri di richiesta del modello esclusivi dei modelli Amazon Nova, come `reasoningConfig` e `TopK`, questi vengono inseriti all'interno di un oggetto aggiuntivo all'interno di `inferenceConfig` `additionalModelRequestFields`. Si tratta di parametri di primo livello per `e. InvokeModel` `InvokeModelWithResponseStream`.

Note

Consulta gli esempi di codice e la risoluzione dei problemi per un elenco di esempi di codice con i modelli Nova 2.

Imposta uno dei seguenti per utilizzare i modelli Amazon Nova: `modelId`

Modello	ID modello
Nova 2 Lite	• <code>global.amazon.nova-2-lite-v1:0</code> • <code>it.amazon.nova-2-lite-v 1:0</code>
Nova 2 Sonic	• <code>global.amazon.nova-2-sonic-v 1:0</code> • <code>it.amazon.nova-2-sonic-v 1:0</code>
Incorporamenti multimodali Nova	<code>amazon.nova-2-1:0 multimodal-embeddings-v</code>

Importante: configurazione del timeout

Important

Il completamento delle richieste di inferenza di Amazon Nova può richiedere fino a 60 minuti. Configura di conseguenza le impostazioni di timeout del client:

L'esempio seguente è il codice Python. Gli utenti possono controllare la documentazione per la versione del linguaggio SDK preferita nei documenti API di quell'SDK.

```
from botocore.config import Config

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

Argomenti di inferenza principali

Questa sezione tratta i seguenti argomenti:

- Utilizzo dell'API converse: un'interfaccia coerente che offre compatibilità con la maggior parte dei modelli Bedrock

- Utilizzo dell'API invoke: un'interfaccia unica per i modelli Nova e non portabile su altri modelli Bedrock
- Risposte in streaming: generazione di risposte in tempo reale
- Utilizzo degli incorporamenti di Amazon Nova: funzionalità di incorporamento di testo
- Inferenza su richiesta: modello di inferenza Pay-per-use

Utilizzo dell'API Converse

L'API Converse fornisce un'interfaccia unificata per interagire con i modelli Amazon Nova. Riduce i dettagli specifici del modello e fornisce un modo coerente per gestire conversazioni a più turni, richieste di sistema e risposte in streaming su tutti i modelli Amazon Nova.

Argomenti

- [Struttura delle richieste](#)
- [Utilizzo delle istruzioni di sistema](#)
- [Parametri di inferenza](#)
- [Usare il ragionamento](#)

Struttura delle richieste

- Conversazioni a turni multipli: mantieni il contesto tra più scambi
- Istruzioni di sistema: istruzioni di sistema come personaggi o linee guida di risposta
- Chat documentale: interagisci e interroga documenti o raccolte di documenti
- Visione: elabora e analizza immagini e video
- Utilizzo degli strumenti: consente ai modelli di utilizzare strumenti esterni e APIs
- Guardrails: applica il filtraggio dei contenuti e i controlli di sicurezza
- Ragionamento: pensiero esteso per la risoluzione di problemi complessi

Una richiesta API Converse di base include l'ID del modello e un elenco di messaggi:

```
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)
```

Utilizzo delle istruzioni di sistema

I prompt di sistema forniscono contesto e istruzioni al modello:

```
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)
```

Parametri di inferenza

Controlla l'output del modello utilizzando i parametri di inferenza. Di seguito sono riportati i parametri di inferenza disponibili.

- **maxTokens** (intero): numero massimo di token da generare (fino a 65.000). Se non specificato, il modello utilizza un valore predefinito dinamico basato sul contesto della richiesta.
- **temperature** (float): controlla la casualità (0,0-1,0, impostazione predefinita 0,7). I valori più bassi rendono l'output più deterministico
- **topP** (float): soglia di campionamento del nucleo (0-1, impostazione predefinita 0,9). I valori più bassi rendono l'output più mirato
- **stopSequences** (array): sequenze di caratteri che interrompono la generazione quando vengono incontrate

Esempio:

```
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)
```

Usare il ragionamento

Nova 2 Lite supporta il pensiero esteso per la risoluzione di problemi complessi. Abilita il ragionamento con `reasoningConfig`

Per impostazione predefinita, il ragionamento è disabilitato per ottimizzare la velocità e i costi delle query semplici. Quando hai bisogno di andare oltre queste semplici attività, puoi abilitare il ragionamento. Nova 2 offre un controllo flessibile sulla profondità del ragionamento attraverso tre livelli di sforzo:

Sforzo basso () `maxReasoningEffort: "low"`

IDEALE PER: ATTIVITÀ CON MAGGIORE COMPLESSITÀ CHE RICHIEDONO UN PENSIERO STRUTTURATO. Ad esempio, è possibile utilizzarlo per suggerimenti di revisione e miglioramento del codice laddove il modello debba considerare attentamente la qualità del codice esistente, attività di analisi che richiedono un'attenta considerazione di più fattori o scenari di risoluzione dei problemi che traggono vantaggio da un approccio metodico. Lo sforzo ridotto è ideale per attività complesse in cui il ragionamento di base migliora la precisione senza richiedere una pianificazione approfondita in più fasi.

Sforzo medio () `maxReasoningEffort: "medium"`

IDEALE PER: ATTIVITÀ IN PIÙ FASI E FLUSSI DI LAVORO DI CODIFICA. Ad esempio, è possibile utilizzarlo per lo sviluppo e il debug di software in cui il modello deve comprendere la struttura del codice esistente prima di implementare le modifiche, la generazione di codice che richiede il coordinamento tra più file o componenti, calcoli in più fasi con interdipendenze o attività di pianificazione con più vincoli. Lo sforzo medio è ottimale per i flussi di lavoro agentic che coordinano più strumenti e richiedono che il modello mantenga il contesto in diverse operazioni sequenziali.

Sforzo elevato () `maxReasoningEffort: "high"`

IDEALE PER: RAGIONAMENTO MATEMATICO E RISOLUZIONE AVANZATA DEI PROBLEMI. Ad esempio, è possibile utilizzarlo per problemi e dimostrazioni matematiche avanzati che richiedono step-by-step verifiche rigorose, analisi scientifiche e attività di ricerca che richiedono indagini approfondite, progettazione di sistemi complessi con considerazioni architettoniche su più dimensioni o scenari decisionali critici con implicazioni significative. Un impegno elevato garantisce la massima precisione per le attività che richiedono un ragionamento sofisticato, un'attenta valutazione delle alternative e una convalida approfondita delle conclusioni.

Gli esempi seguenti mostrano diversi livelli di sforzo di ragionamento:

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"
        }
    }
)
```

Parametri di ragionamento:

Di seguito sono riportati i parametri di ragionamento

- `type`: `enabled` o `disabled` (impostazione predefinita: `disabled`)
- `maxReasoningEffort`: `low`, `medium`, `high`. Questo è necessario quando il ragionamento è abilitato.

Note

Temperature, TopP e TopK non possono essere utilizzati con `maxReasoningEffort` set to `high`. Ciò causerà un errore.

La risposta include il contenuto del ragionamento:

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

Note

Con Amazon Nova 2, i contenuti di ragionamento vengono visualizzati come [REDACTED]. I token di ragionamento ti verranno comunque addebitati perché contribuiscono a migliorare la qualità dell'output. Includiamo ora questo campo nella struttura delle risposte per preservare la possibilità di esporre il contenuto del ragionamento in futuro. Stiamo lavorando attivamente con i clienti per determinare l'approccio migliore per far emergere il processo di ragionamento del modello.

Utilizzo dell'API Invoke

L'API Invoke fornisce l'accesso diretto ai modelli Amazon Nova con una maggiore capacità di controllare il formato di richiesta e risposta. A differenza dell'API Converse che astrae i dettagli specifici del modello, l'API Invoke consente di lavorare direttamente con le strutture di richiesta e risposta native del modello.

 Note

L'API Invoke supporta le stesse funzionalità dell'API Converse ad eccezione della modalità di immissione dei documenti, che è specifica dell'API Converse.

Struttura della richiesta

Una richiesta API Invoke richiede l'ID del modello e un corpo della richiesta JSON:

```
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"])
```


Parametri della richiesta

L'API Invoke supporta i seguenti parametri chiave:

- **messages**: serie di messaggi di conversazione con ruolo e contenuto
- **system**: Richiesta di sistema opzionale per il contesto e le istruzioni
- **inferenceConfig**: Parametri che controllano l'output del modello (temperature, maxTokens, TopP, TopK, stopSequences, ReasoningConfig)
- **toolConfig**: Specifiche degli strumenti e scelta degli strumenti per la chiamata delle funzioni

Streaming delle risposte

Lo streaming consente di ricevere le risposte dei modelli in modo incrementale man mano che vengono generate, offrendo un'esperienza utente più interattiva. Sia l'API Converse che l'API Invoke supportano lo streaming.

Streaming con ConverseStream

Utilizza `ConverseStream` per ricevere risposte sotto forma di flusso di eventi:

```
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)
```

Streaming con InvokeModelWithResponseStream

Utilizzalo `InvokeModelWithResponseStream` per lo streaming con l'API `Invoke`:

```
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)
```

Tipi di eventi in streaming

Le risposte in streaming includono diversi tipi di eventi:

- `messageStart`: indica l'inizio di un messaggio
- `contentBlockStart`: indica l'inizio di un blocco di contenuto
- `contentBlockDelta`: contiene testo o dati incrementali
- `contentBlockStop`: indica la fine di un blocco di contenuto
- `messageStop`: Indica la fine del messaggio con il motivo dell'interruzione
- `metadata`: contiene informazioni sull'utilizzo (numero di token)

Utilizzo degli incorporamenti Amazon Nova

Amazon Nova Multimodal Embeddings è un modello di incorporamento multimodale per RAG agentici e applicazioni di ricerca semantica. Supporta testo, documenti, immagini, video e audio attraverso un unico modello, che consente il recupero intermodale. Nova Multimodal Embeddings mappa ciascuno di questi tipi di contenuto in uno spazio semantico unificato, consentendovi di condurre operazioni vettoriali unimodali, intermodali e multimodali.

Quando un contenuto viene passato attraverso gli embedding Nova, il modello converte quel contenuto in un formato numerico universale, denominato vettore. Un vettore è un insieme di valori numerici che possono essere utilizzati per varie funzionalità di ricerca. Ai contenuti simili viene assegnato un vettore più ravvicinato rispetto ai contenuti meno simili.

Applicazioni:

- Recupero e raccomandazione di contenuti semantici: genera incorporamenti per i tuoi contenuti, quindi usali per trovare articoli simili o fornire consigli personalizzati.
- Ricerca multimodale: combina gli incorporamenti di diversi tipi di contenuto per abilitare funzionalità di ricerca intermodale.
- RAG: genera embedding da contenuti multimodali, come documenti con testo e immagini interleaved, per potenziare il flusso di lavoro di recupero per le applicazioni GenAI.

Funzionalità principali

Queste caratteristiche chiave contraddistinguono Nova Embeddings:

- Supporto per testo, immagini, immagini di documenti, video e audio in uno spazio semantico unificato. La lunghezza massima del contesto è di 8K token o 30 secondi di video e 30 secondi di audio.
- Sincrono e asincrono APIs: l'API supporta sia l'uso sincrono che asincrono.
- Segmentazione di file di grandi dimensioni: l'API asincrona semplifica la gestione di input di grandi dimensioni fornendo una segmentazione integrata nell'API per testi lunghi, video e audio, controllata da parametri definiti dall'utente. Il modello genererà un singolo embedding per ogni segmento.
- Video con audio: elaborazione simultanea di video e audio. Specificate se desiderate un singolo incorporamento che rappresenti entrambe le modalità o due incorporamenti separati.

- Scopo dell'incorporamento: ottimizza gli incorporamenti in base all'applicazione downstream prevista (retrieval/RAG/Searchclassificazione, clustering).
- Dimensioni: 4 dimensioni per bilanciare la precisione di embedding e il costo di archiviazione dei vettori: 3072; 1024; 384; 256.
- Metodi di input: trasferisci il contenuto da incorporare specificando un URI S3 o in linea come codifica base64.

Generazione di incorporamenti

Completa quanto segue per generare incorporamenti.

Incorporamento sincrono per il testo:

```
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))
```

prova:

```
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))
```

Incorporamento asincrono per 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
#####},
#####},
####},
}
```

prova:

```
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'))
```

Inferenza in batch

Con l'inferenza in batch, puoi inviare più richieste e generare incorporamenti in modo asincrono. L'inferenza in batch ti aiuta a elaborare molte richieste in modo efficiente inviando una singola richiesta e generando risposte in un bucket Amazon S3.

- Dopo aver definito gli input del modello nei file creati, i file verranno caricati in un bucket S3.
- A questo punto, invia una richiesta di inferenza in batch e specifica il bucket S3.
- Al termine del processo, puoi recuperare i file di output da S3.
- Puoi utilizzare l'inferenza in batch per migliorare le prestazioni dell'inferenza del modello su set di dati di grandi dimensioni.

Formatta e carica i dati di inferenza in batch

I dati per l'inferenza in batch devono essere aggiunti a una posizione S3 da scegliere o specificare quando invii un processo di invocazione del modello. La sede S3 deve contenere i seguenti elementi:

Almeno un file JSONL che definisce gli input del modello. Un JSONL contiene righe di oggetti JSON. Il file JSONL deve terminare con l'estensione .jsonl ed avere il seguente formato:

```
{
  "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"
      }
    }
  }
}
```

Tipi di file di input supportati

- Formati di immagine: PNG, JPEG, WEBP, GIF
- Formati audio: WAV MP3, OGG
- Formati video: MOV MP4, MKV, WEBM, FLV, MPEG, MPG, WMV, 3GP

Inferenza on demand

L'inferenza su richiesta fornisce l'accesso senza server ai modelli Amazon Nova senza richiedere capacità predisposta. Questa modalità si ridimensiona automaticamente per gestire il carico di lavoro e gli addebiti in base all'utilizzo.

Vantaggi

L'inferenza su richiesta offre diversi vantaggi:

- Nessuna pianificazione della capacità: scalabilità automatica per soddisfare la domanda
- Pagamento in base all'utilizzo: viene addebitato solo per i token elaborati
- Disponibilità immediata: non è richiesto alcun tempo di approvvigionamento o riscaldamento
- Conveniente: ideale per carichi di lavoro variabili o imprevedibili

Utilizzo dell'inferenza su richiesta

L'inferenza su richiesta è la modalità predefinita per i modelli Amazon Nova. È sufficiente specificare l'ID del modello quando si effettuano chiamate API:

```
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)
```

Prezzi

L'inferenza su richiesta viene fatturata in base al numero di token di input e output elaborati. Per informazioni sui prezzi correnti, consulta i [prezzi di Amazon Bedrock](#).

Quote e limiti

L'inferenza su richiesta ha quote predefinite che variano in base al modello e alla regione. Per richiedere aumenti delle quote, usa la console [Service Quotas](#).

Utilizzo delle funzionalità di Amazon Nova 2

Questa guida fornisce ricette basate su attività ed esempi pratici per aiutarvi a integrare le funzionalità di Nova nelle vostre applicazioni in modo rapido ed efficace. È progettata per sviluppatori e ingegneri che desiderano:

- Integrare i modelli Nova nelle loro applicazioni tramite API
- Comprendi i requisiti di preelaborazione e le strategie di ottimizzazione
- Implementa flussi di lavoro di comprensione multimodali

Ogni sezione fornisce:

- Informazioni tecniche chiave sui formati supportati, sui limiti di dimensione e sulla stima dei token
- Esempi di codice che dimostrano come utilizzare l'API sia con il caricamento diretto che con Amazon S3
- Casi d'uso che mostrano applicazioni pratiche
- Limitazioni da considerare durante la progettazione dell'applicazione

Prerequisiti

Prima di iniziare, assicurati di disporre dei seguenti elementi:

- E Account AWS con accesso ad Amazon Bedrock
- Autorizzazioni IAM appropriate per richiamare i modelli Bedrock
- AWS SDK installato (esempi di Boto3 per Python)
- Familiarità di base con AWS servizi come Amazon S3 (per la gestione di file di grandi dimensioni)

Capacità di ragionamento

Amazon Nova 2 Lite supporta il pensiero esteso, che è disabilitato per impostazione predefinita. Se abilitato, il modello genera token di ragionamento interni che migliorano la qualità della risposta. In Amazon Nova 2 Lite, il contenuto del ragionamento viene oscurato nell'output e viene visualizzato come [REDACTED] se questi token fossero comunque a pagamento.

Il campo di ragionamento è incluso nella struttura delle risposte per preservare la possibilità di esporre questo contenuto nelle versioni future. Per ulteriori informazioni sull'Extended Thinking, vedere [the section called “Pensiero esteso”](#) e [the section called “Libreria di codici”](#)

Comprensione multimodale

Amazon Nova 2 Lite è in grado di comprendere diverse modalità di input. Questo modello è dotato di funzionalità di visione che gli consentono di comprendere e analizzare immagini, documenti, video e comandi vocali per inferire e rispondere a domande in base al contenuto fornito.

Questa sezione descrive le linee guida per lavorare con immagini, documenti e video in Amazon Nova, comprese le strategie di preelaborazione utilizzate, esempi di codice e le limitazioni pertinenti da considerare.

Tipo di contenuto supportato per modalità

Le seguenti informazioni descrivono in dettaglio i formati di file supportati da ciascun tipo di file multimediale e il metodo di input accettato.

Tipo di file multimediale	Formati di file supportati	Metodo di input	Limiti di dimensione	Numero di oggetti
Immagine	PNG, JPEG, GIF, WebP	Incorporamento dei dati nella richiesta	25 MB	5
	Nota: se utilizzate un file GIF o WebP animato, verrà utilizzato solo il primo fotogramma.	Se utilizzi l'API Converse, codifica i dati come byte. Se utilizzi l'API Invoke, codifica i dati come stringa Base64.		
		URI Amazon S3	2 GB in totale	1000
Video	MP4, MOV, MKV, WebM, FLV, MPEG,	Incorporamento dei dati nella richiesta	25 MB	1
		Se utilizzi l'API Converse, codifica i dati come byte.		

Tipo di file multimediale	Formati di file supportati	Metodo di input	Limiti di dimensione	Numero di oggetti
	MPG, WMV, 3GP	Se utilizzi l'API Invoke, codifica i dati come stringa Base64.		
		URI Amazon S3	1 GB	1

Argomenti

- [Comprensione delle immagini](#)
- [Comprensione dei video](#)
- [Comprensione dei documenti](#)

Comprensione delle immagini

La comprensione delle immagini si riferisce alla capacità di Amazon Nova di elaborare un'immagine e condurre una serie di attività di visione artificiale come:

- Esecuzione del rilevamento di oggetti
- Risposta a domande sulle immagini tramite Visual Question Answering (VQA)
- Classificazione e riepilogo delle immagini
- Esecuzione del rilevamento del bounding box
- Riconoscimento ottico dei caratteri (OCR)
- Conteggio degli oggetti

Le immagini possono essere incluse come prompt passato all'API come array di byte o tramite URI S3.

Informazioni tecniche chiave

Di seguito sono riportate le informazioni tecniche chiave da tenere presente quando si utilizza questa funzionalità.

Ridimensionamento e ridimensionamento delle immagini

Amazon Nova ridimensiona automaticamente le immagini per ottimizzare qualità e prestazioni:

- Determina le proporzioni più vicine (ad esempio 1:1, 1:2, 2:3 e così via)
- Ridimensiona in modo che un lato sia ≥ 896 px o corrisponda al lato più corto dell'immagine originale, a seconda di quale dei due sia più grande
- Mantiene le proporzioni
- Supporta una risoluzione fino a 8.000×8.000 px

Coordinate del riquadro di delimitazione:

- Utile per attività come l'identificazione di elementi nelle schermate o la messa a terra delle immagini
- Le coordinate possono essere ridimensionate in modo che corrispondano alle dimensioni originali dell'immagine in fase di post-elaborazione
- Restituisce i riquadri di delimitazione su una scala [0, 1000].

Stima dei token di immagine

Amazon Nova converte ogni immagine in token per l'elaborazione. Il numero di token dipende dalla risoluzione e dalle proporzioni dell'immagine.

Di seguito sono riportati alcuni esempi di conteggio approssimativo dei token in base alla risoluzione dell'immagine:

Risoluzione dell'immagine	Token stimati
900 x 450	515
900 x 900	~1.035
1400 x 900	~1.600
1800 x 900	~2.060
1300 x 1300	~2.155

Esempi di comprensione delle immagini

Per un esempio di come incorporare i dati delle immagini direttamente nella richiesta, fai riferimento all'esempio Multimodal input using embedded asset - Converse API (non-streaming) in. [Libreria di codici](#)

Per caricare file di immagini di grandi dimensioni o più file di immagine, in cui il carico utile complessivo è superiore a 25 MB, usa Amazon S3. Per un esempio completo di come utilizzare i riferimenti URI di Amazon S3 per l'input di immagini, consulta l'esempio Input multimodal using S3 URI - Converse API (non-streaming) in. [Libreria di codici](#)

Note

Quando usi S3, assicurati che il servizio Amazon Bedrock disponga dell'autorizzazione per accedere al bucket e all'oggetto.

Limitazioni principali

L'elenco seguente descrive le attuali limitazioni dei modelli di comprensione delle immagini:

- **Comprensione multilingue delle immagini:** i modelli hanno una comprensione limitata delle immagini e dei fotogrammi video multilingue e possono avere difficoltà o allucinazioni su compiti semplici.
- **Identificazione delle persone:** i modelli Amazon Nova 2 non supportano la capacità di identificare o nominare persone in immagini, documenti o video.
- **Ragionamento spaziale:** i modelli Amazon Nova 2 hanno capacità di ragionamento spaziale limitate. Possono avere difficoltà a svolgere attività che richiedono una localizzazione precisa o un'analisi del layout.
- **Testo piccolo nelle immagini e nei video:** se il testo dell'immagine o del video è troppo piccolo, valuta la possibilità di aumentare la dimensione relativa del testo nell'immagine ritagliandolo nella sezione pertinente e preservando il contesto necessario.

Comprensione dei video

La comprensione video si riferisce alla capacità di Amazon Nova di elaborare input video ed eseguire una serie di attività di comprensione video come:

- Analisi dei frame chiave e riepilogo dei contenuti video
- Rispondere a domande sui segmenti video (Video Question Answering o Video QA)
- Rilevamento e tracciamento di oggetti tra i frame
- Identificazione di azioni, scene ed eventi
- Esecuzione della segmentazione temporale per individuare momenti specifici
- Generazione di didascalie o riassunti descrittivi di sequenze video

Informazioni tecniche chiave

Di seguito sono riportate le informazioni tecniche chiave da tenere presente quando si utilizza questa funzionalità.

Informazioni sulle dimensioni del video

Le funzionalità di comprensione video di Amazon Nova supportano il formato multiaspetto. Tutti i video vengono ridimensionati con distorsione (verso l'alto o verso il basso, in base alle proporzioni originali) a 672×672 dimensioni quadrate prima di essere inseriti nel modello.

Il modello utilizza una strategia di campionamento dinamico basata sulla lunghezza del video. Per i video di durata pari o inferiore a 16 minuti, Amazon Nova 2 Lite campiona 1 fotogramma al secondo (FPS). Per i video di durata superiore a 16 minuti, la frequenza di campionamento diminuisce per mantenere un campionamento costante di 960 fotogrammi, con la frequenza di campionamento dei fotogrammi che varia di conseguenza. Questo approccio è pensato per fornire una comprensione dei video più accurata a livello di scena per video più brevi rispetto a contenuti video più lunghi.

Ti consigliamo di mantenere la lunghezza del video inferiore a 1 ora per il basso movimento e meno di 16 minuti per i video ad alto movimento.

Non dovrebbero esserci differenze tra l'analisi di una versione 4K e una versione Full HD di un video. Analogamente, poiché la frequenza di campionamento è di 1 FPS, un video a 60 FPS dovrebbe funzionare come un video a 30 FPS. L'utilizzo di una risoluzione e di FPS superiori a quelli richiesti non è vantaggioso a causa del limite di 1 GB nella dimensione del video. In questo modo limiterai la lunghezza del video che rientra in quel limite di dimensione, quindi potresti voler pre-elaborare video più lunghi di 1 GB.

Token video

La lunghezza del video è il fattore principale che influisce sul numero di token generati. Per calcolare il costo approssimativo, moltiplica il numero stimato di token video per il prezzo per token del modello specifico utilizzato.

La tabella seguente fornisce alcune approssimazioni del campionamento dei frame e dell'utilizzo dei token per lunghezza video per Amazon Nova 2 Lite:

Lunghezza del video	Cornici da campionare	Frequenza di campionamento (fps)	Token approssimativi
10 secondi	10	1	2.880
30 secondi	30	1	8.640
16 minuti	960	1	276.480
20 minuti	1200	1	345.600
30 minuti	1800	1	518.400
45 minuti	2700	1	777.600

Esempi di comprensione dei video

Per un esempio di come incorporare i dati video direttamente nella richiesta, fai riferimento all'esempio Multimodal input using embedded asset - Converse API (non streaming) in. [Libreria di codici](#)

Per un esempio di come utilizzare i riferimenti URI S3 nell'input video, fai riferimento all'esempio di input multimodal che utilizza S3 URI - Converse API (non streaming) in. [Libreria di codici](#)

Limitazioni principali

Di seguito sono riportate le principali limitazioni del modello, in cui la precisione e le prestazioni del modello potrebbero non essere garantite:

- **Nessun supporto audio:** i modelli Amazon Nova sono attualmente addestrati per elaborare e comprendere i contenuti video esclusivamente in base ai frame visivi. Le tracce audio nei video non vengono elaborate o analizzate.
- **Comprensione multilingue delle immagini:** i modelli Amazon Nova hanno una comprensione limitata delle immagini e dei frame video multilingue. Potrebbero avere difficoltà o avere allucinazioni durante compiti semplici.
- **Identificazione delle persone:** i modelli Amazon Nova non supportano la capacità di identificare o nominare persone in immagini, documenti o video. I modelli non forniranno nomi o identità di persone nei contenuti visivi.
- **Testo piccolo nei video:** se il testo dell'immagine o del video è troppo piccolo, valuta la possibilità di aumentare la dimensione relativa del testo nel video.
- **Ragionamento spaziale:** i modelli Amazon Nova 2 hanno capacità di ragionamento spaziale limitate. Possono avere difficoltà a svolgere attività che richiedono una comprensione precisa delle posizioni, delle distanze o delle relazioni spaziali degli oggetti nei video.
- **Contenuti inappropriati:** i modelli Amazon Nova non elaboreranno immagini inappropriate o esplicite che violano la Policy di utilizzo accettabile
- **Applicazioni sanitarie:** a causa della natura sensibile di questi artefatti, anche se i modelli Amazon Nova potrebbero fornire analisi generali su alcune immagini o video sanitari, non ne consigliamo l'uso per interpretare immagini mediche sensibili come scansioni diagnostiche complesse. La risposta dei modelli Amazon Nova non deve mai essere considerata un sostituto della consulenza medica professionale.

Comprensione dei documenti

La funzionalità di comprensione dei documenti di Amazon Nova ti consente di includere interi documenti (file WordPDFs, fogli di calcolo e così via) come parte del prompt. Ciò consente al modello di analizzare, riepilogare, estrarre informazioni o rispondere a domande sul contenuto del documento.

Amazon Nova 2 Lite può interpretare sia il testo che gli elementi visivi (come grafici o tabelle) all'interno di questi documenti. Ciò consente casi d'uso come la risposta a domande, il riepilogo e l'analisi di report lunghi o documenti scansionati.

Le principali funzionalità di comprensione dei documenti includono una finestra contestuale molto ampia (1 milione di token) per documenti lunghi e la capacità di gestire più documenti in un'unica query.

Modalità e formati di documenti supportati

Amazon Nova distingue due tipi di input di documenti:

- I documenti basati su testo, come i file TXT, CSV, HTML, Markdown o DOC, vengono elaborati principalmente per il loro contenuto testuale. Amazon Nova comprende ed estrae informazioni dal testo di questi documenti.
- I documenti multimediali, come i file PDF o DOCX, possono contenere layout complessi, immagini, grafici o grafica incorporata. Per i documenti multimediali, Amazon Nova utilizza la comprensione basata sulla visione per interpretare i contenuti visivi, come grafici, tabelle, diagrammi o schermate, insieme al testo del documento.

I formati di file supportati includono tipi di documenti comuni come:

- File di testo semplice e di testo strutturato: CSV, TXT
- Fogli di calcolo: XLS, XLSX, HTML, Markdown
- Formati di immagine standard (per immagini all'interno di documenti): PNG, JPG, GIF, WebP
- Formati di documenti: DOC, DOCX, PDF
- PDFs che contengono codifiche di immagini, come CMYK o SVG, non sono supportate.

Limiti di dimensione dei documenti e linee guida per l'utilizzo

Vincolo	Limite
Numero massimo di documenti	Fino a 5 documenti per richiesta (valido sia per il caricamento diretto che per Amazon S3)
Dimensioni del documento basato su testo	Ogni documento di testo deve essere uguale o inferiore a 4,5 MB
Dimensioni del documento basato su supporti	Per i file PDF e DOCX, non esiste un limite alla dimensione dei singoli file. Quando si utilizza il caricamento diretto, la dimensione combinata di tutti i documenti multimediali deve essere inferiore o uguale a 25 MB. Quando si utilizza Amazon S3, la dimensione combinata di tutti i

Vincolo	Limite
	documenti multimediali deve essere inferiore o uguale a 2 GB.
Contenuti PDF non supportati	PDFs che contengono profili di colore CMYK o immagini SVG non sono supportati.

Prezzi

Amazon Nova utilizza prezzi basati su token: paghi per i token di input (tutto ciò che invii, inclusi i documenti allegati) e i token di output (la risposta del modello).

Stima dei token per PDFs: Per la pianificazione, supponiamo una pagina PDF standard da 8,5x11 pollici con 2.560 token di input (questa stima copre sia gli elementi di testo che quelli visivi di una pagina tipica).

Esempi: utilizzo della comprensione dei documenti di Nova tramite API e S3

Per un esempio di come utilizzarlo tramite API, fai riferimento all'esempio Multimodal input using embedded asset - Converse API (non streaming) in. [Libreria di codici](#)

Per un esempio di utilizzo tramite S3, fai riferimento all'esempio Multimodal input using S3 URI - Converse API (non streaming) in. [Libreria di codici](#)

Speech-to-Speech (Amazon Nova 2 Sonic)

Amazon Nova 2 Sonic abilita l'intelligenza artificiale conversazionale in tempo reale con input e output vocali. La sezione seguente illustra le funzionalità avanzate per la creazione di assistenti vocali interattivi, l'automazione del servizio clienti e le applicazioni conversazionali.

Funzionalità principali

Amazon Nova 2 Sonic offre le seguenti funzionalità:

- State-of-the-art comprensione vocale in streaming con API di streaming bidirezionale che consente conversazioni a più turni in tempo reale e a bassa latenza.
- Supporto multilingue con rilevamento e cambio automatico della lingua. Sono disponibili voci espressive, comprese voci maschili e femminili, nelle seguenti lingue:
 - Inglese (Stati Uniti, Regno Unito, India, Australia)
 - Francese
 - Italiano
 - Tedesco
 - Spagnolo
 - Portoghese
 - Hindi
- Voci poliglote in grado di parlare una qualsiasi delle lingue supportate per consentire un'esperienza utente coerente anche quando l'utente cambia lingua all'interno della stessa sessione.
- Robustezza rispetto al rumore di fondo per scenari di implementazione nel mondo reale.
- Robustezza a diversi accenti per le lingue supportate.
- Esperienze di intelligenza artificiale conversazionale naturali e simili a quelle umane con ricchezza contestuale in tutte le lingue supportate.
- Risposta vocale adattiva che regola dinamicamente la riproduzione in base alla prosodia del discorso di input.
- Intervento intelligente che rileva quando gli utenti finiscono di parlare e quando l'assistente deve rispondere, creando un ritmo di dialogo naturale.
- Gestione agevole delle interruzioni degli utenti senza alterare il contesto della conversazione.

- Contestualizzazione delle conoscenze con dati aziendali grazie alla generazione potenziata da recupero dati (RAG).
- Chiamata di funzioni e supporto del flusso di lavoro agentico per la creazione di applicazioni di IA complesse.
- Gestione asincrona degli strumenti che esegue le chiamate agli strumenti mantenendo il flusso di conversazione, permettendo all'assistente di continuare a parlare mentre gli strumenti procedono in background.
- Supporto di input intermodale per input audio e di testo all'interno della stessa conversazione, che consente modelli di interazione flessibili.
- Limite di connessione di 8 minuti, con rinnovo della connessione e schema di continuazione della sessione disponibili negli esempi di codice.

Guida introduttiva con speech-to-speech

Le seguenti sezioni forniscono un esempio e una step-by-step spiegazione di come implementare un'applicazione di streaming audio semplice e in tempo reale utilizzando Amazon Nova 2 Sonic. Questa versione semplificata dimostra le funzionalità di base necessarie per creare una conversazione audio con il modello Amazon Nova 2 Sonic.

Puoi accedere al seguente esempio nel nostro repository di esempi [Nova](#). GitHub

È previsto un limite di connessione di 8 minuti, con rinnovo della connessione e schema di continuazione della conversazione disponibili su. [GitHub](#)

Indica le importazioni e la configurazione

Questa sezione importa le librerie necessarie e imposta i parametri di configurazione audio:

- `asyncio`: per la programmazione asincrona
- `base64`: per codificare e decodificare dati audio
- `pyaudio`: per l'acquisizione e la riproduzione audio
- Componenti Amazon Bedrock SDK per lo streaming
- Le costanti audio definiscono il formato di acquisizione audio (frequenza di campionamento 16 kHz, canale mono)

```
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
```

Definisci la classe **SimpleNovaSonic**

La classe SimpleNovaSonic è la classe principale che gestisce l'interazione di Amazon Nova Sonic:

- `model_id`: ID del modello Amazon Nova Sonic (`amazon.nova-2-sonic-v1:0`)
- `region`: La AWS regione, l'impostazione predefinita è `us-east-1`
- Unico IDs per il monitoraggio tempestivo e dei contenuti
- Una coda asincrona per la riproduzione audio

```
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
```

Inizializza il client

Questo metodo configura il client Amazon Bedrock con quanto segue:

- L'endpoint appropriato per la regione specificata
- Informazioni di autenticazione che usano variabili di ambiente per le credenziali AWS
- Lo schema di autenticazione SigV4 per le chiamate API AWS

```
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)
```

Gestione degli eventi

Questo assistente di gestione invia eventi JSON allo streaming bidirezionale, utilizzato per tutte le comunicazioni con il modello Amazon Nova Sonic:

```
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)
```

Avvia la sessione

Questo metodo avvia la sessione e configura gli eventi rimanenti per avviare lo streaming audio. Questi eventi devono essere inviati nello stesso ordine.

```

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())

```

Gestione dell'input audio

Questi metodi gestiscono il ciclo di vita dell'input audio:

- `start_audio_input`: configura e avvia il flusso di input audio
- `send_audio_chunk`: codifica e invia blocchi audio al modello
- `end_audio_input`: chiude correttamente il flusso di input audio

```

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)
```

Termina la sessione

Questo metodo chiude correttamente la sessione nei seguenti modi:

- Inviando un evento `promptEnd`
- Inviando un evento `sessionEnd`
- Chiudendo lo streaming di input

```
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()
```

Gestione delle risposte

Questo metodo elabora continuamente le risposte del modello ed esegue le seguenti operazioni:

- Attende l'output dallo streaming.
- Analizza la risposta JSON.
- Gestisce l'output di testo stampandolo sulla console con riconoscimento vocale e trascrizione automatici.
- Gestisce l'output audio mediante la decodifica e l'accodamento per la riproduzione.

```

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}")
```

Riproduzione audio

Questo metodo eseguirà le seguenti attività:

- Inizializza un flusso di input PyAudio
- Recupera continuamente i dati audio dalla coda
- Riproduce l'audio tramite gli altoparlanti
- Elimina correttamente le risorse una volta terminato

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

prova:

```
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()
```

Acquisizione audio

Questo metodo eseguirà le seguenti attività:

- Inizializza un flusso di output PyAudio
- Avvia la sessione di input audio
- Acquisisce blocchi audio dal microfono in modo continuo
- Invia ogni blocco al modello Amazon Nova Sonic
- Elimina correttamente le risorse una volta terminato

```
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()
```

prova:

```
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()
```

Esecuzione della funzione principale.

La funzione principale orchestra l'intero processo svolgendo le seguenti operazioni:

- Crea un client Amazon Nova 2 Sonic
- Avvia la sessione
- Crea attività simultanee per la riproduzione e l'acquisizione audio
- Attende che l'utente prema per interrompere **Enter**
- Termina correttamente la sessione ed elimina le attività

```
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())
```

Esempi di codice

Questi esempi di codice ti aiutano a iniziare rapidamente a usare Amazon Nova 2 Sonic. Puoi accedere all'elenco completo degli esempi nella pagina degli [GitHub esempi di Amazon Nova Sonic](#).

Esempi di nozioni di base

Per esempi semplici progettati per iniziare a utilizzare Amazon Nova 2 Sonic, fai riferimento alle seguenti implementazioni:

- [Implementazione di base di Amazon Nova 2 Sonic \(Python\)](#): un'implementazione di base che dimostra come gli eventi sono strutturati nell'API di streaming bidirezionale. Questa versione non supporta la funzionalità barge-in (interruzione dell'assistente mentre sta parlando) e non implementa una vera comunicazione bidirezionale.
- [Implementazione completa di Amazon Nova 2 Sonic \(Python\)](#): l'implementazione completa con comunicazione bidirezionale reale e supporto integrato. Ciò consente conversazioni più naturali in cui gli utenti possono interrompere l'assistente mentre sta parlando, in modo simile alle conversazioni umane.

- [Amazon Nova 2 Sonic con utilizzo di strumenti \(Python\)](#): un'implementazione avanzata che estende le funzionalità di comunicazione bidirezionale con esempi di utilizzo degli strumenti. Questa versione dimostra come Amazon Nova 2 Sonic può interagire con strumenti esterni e APIs fornire funzionalità avanzate.
- [Nova Sonic con testo e input misto \(Python\)](#): esempio di implementazione per mostrare come Amazon Nova 2 Sonic può avere testo come input.
- [WebSocket Implementazione Java \(Java\)](#): questo esempio implementa un'applicazione di streaming audio bidirezionale WebSocket che si integra con Amazon Nova 2 Sonic per speech-to-speech conversazioni in tempo reale tramite Java.
- [Implementazione NodeJS Websocket \(NodeJS\)](#): questo esempio implementa un'applicazione di streaming audio WebSocket bidirezionale che si integra con Amazon Nova 2 Sonic per conversazioni in tempo reale utilizzando NodeJS. speech-to-speech
- [Implementazione NodeJS Websocket \(C#\)](#): questo esempio implementa un'applicazione di streaming audio WebSocket bidirezionale che si integra con Amazon Nova 2 Sonic per conversazioni in tempo reale usa.NET. speech-to-speech

Casi d'uso avanzati

Per esempi avanzati che dimostrano casi d'uso più complessi, fai riferimento alle seguenti implementazioni:

- [Implementazione di Amazon Bedrock Knowledge Base \(NodeJS\)](#): questo esempio dimostra come creare un'applicazione conversazionale intelligente integrando Amazon Nova 2 Sonic con Amazon Bedrock Knowledge Base utilizzando NodeJS.
- [Gestione della cronologia chat \(Python\)](#): questo esempio include un sistema di registrazione della cronologia chat che acquisisce e conserva tutte le interazioni tra l'utente e Amazon Nova 2 Sonic tramite Python.
- [Cancellazione delle prenotazioni alberghiere \(NodeJS\)](#): questo esempio illustra un caso d'uso pratico del servizio clienti per Amazon Nova 2 Sonic, che implementa un sistema di cancellazione delle prenotazioni alberghiere utilizzando NodeJS.
- [LangChain Integrazione con la Knowledge Base \(Python\)](#): questa implementazione dimostra come integrare speech-to-speech le funzionalità di Amazon Nova 2 Sonic con una knowledge base LangChain potenziata per esperienze di conversazione migliorate con Python.
- [Conversation Resumption \(NodeJS\)](#): questo esempio dimostra come implementare le funzionalità di ripresa delle conversazioni con Amazon Nova 2 Sonic. Utilizzando uno scenario di cancellazione

della prenotazione alberghiera come contesto, l'applicazione mostra come mantenere lo stato della conversazione tra le sessioni, consentendo agli utenti di continuare senza interruzioni le interazioni che in precedenza erano state interrotte utilizzando NodeJS.

- [Nova 2 Sonic Speaks First \(NodeJS\)](#): questo esempio dimostra come Amazon Nova 2 Sonic può avviare conversazioni in modo proattivo.
- [Continuazione della sessione \(Python\)](#): questo esempio dimostra come abilitare una durata illimitata della conversazione con Amazon Nova 2 Sonic implementando transizioni di sessione senza interruzioni. L'applicazione crea e passa automaticamente a nuove sessioni in background, permettendo alle conversazioni di continuare indefinitamente senza interruzioni o perdita di contesto.

Workshop pratico

È disponibile un workshop pratico che ti guida nella creazione di un'applicazione di chat vocale utilizzando Amazon Nova 2 Sonic con un'interfaccia di streaming bidirezionale. [Puoi accedere al workshop e trovare gli esempi di codice completi.](#)

Istruzioni per le conversazioni vocali

Nova 2 introduce Speech Prompts, una funzionalità di richiesta specializzata progettata per controllare la formattazione della trascrizione specifica del parlato per l'hindi. Le istruzioni vocali funzionano insieme al prompt di sistema, ma hanno uno scopo distinto:

- System Prompt: controlla il comportamento, la personalità e lo stile di risposta dell'assistente
- Speech Prompt: controlla la formattazione della trascrizione per il cambio di codice in hindi (script) Latin/Devanagari/mixed

Linee guida importanti

Le istruzioni vocali sono preconfigurate e devono essere utilizzate esattamente come documentato. Sono progettati per esigenze specifiche di formattazione della trascrizione e non devono essere modificati o personalizzati, poiché le modifiche possono causare comportamenti imprevisti.

Quando utilizzare le istruzioni vocali:

- È necessario controllare l'output dello script per la commutazione di codice in hindi () Latin/Devanagari/mixed

Quando NON usare le istruzioni vocali:

- Per istruzioni generali o sul comportamento dell'assistente (usa invece il prompt di sistema)
- Se non utilizzi la formattazione della trascrizione in hindi
- Se l'esigenza di formattazione specifica non si applica al tuo caso d'uso

Procedura consigliata: includi un messaggio vocale solo se hai bisogno specificamente della formattazione della trascrizione in hindi. Tutte le altre istruzioni, incluse le preferenze di lingua, lo stile di risposta, la verbosità e il ragionamento, devono essere visualizzate nel prompt di sistema.

Importante: le istruzioni vocali devono essere inviate al modello dopo il prompt di sistema.

Prompt di sistema di base consigliato per la voce

```
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.
```

Configurazione del prompt vocale

Commutazione di codice

Nota: attualmente questa funzionalità si applica solo alla lingua hindi.

Scegliete una delle seguenti istruzioni in base allo script di output desiderato:

Per l'output in caratteri latini (hindi romanizzato):

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

Per l'output dello script Devanagari:

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

Per l'output di script misti (commutazione naturale di codice):

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

Configurazione del prompt di sistema

Controllo della verbosità della risposta

Risposte concise e conversazionali:

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.

Risposte dettagliate e complete:

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.

Mirroring linguistico

Nova è in grado di riconoscere e rispondere nella lingua parlata dall'utente. Utilizzate questo prompt per mantenere la coerenza linguistica:

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.

Accordo di genere per le lingue di genere

Alcune lingue richiedono l'accordo di genere nei verbi, negli aggettivi o nei pronomi quando l'assistente descrive se stesso. Per queste lingue, specifica il sesso dell'assistente nel prompt di sistema in modo che corrisponda alla voce selezionata.

Lingue interessate: hindi, portoghese, francese, italiano, spagnolo, russo, polacco

Quando l'accordo di genere è importante:

- Hindi: sempre necessario: i verbi si coniugano in prima persona in base al sesso di chi parla
- Portoghese/francese: necessario quando si usano participi o aggettivi passati (come «Sono stanco» - «Estou cansada/cansado»)
- Italiano/spagnolo: necessario quando si usano aggettivi per descrivere se stessi (come «Sono felice» - «Sono contenta/contento»)

Implementazione:

Includi l'identificatore di genere appropriato all'inizio del prompt di sistema in base alla selezione vocale:

Per voci dal suono femminile (kiara, carolina, ambre, beatrice, lupe, tiffany):

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

Per voci dal suono maschile (arjun, leo, florian, lorenzo, carlos, matthew):

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

Esempi:

Hindi con voce femminile (kiara):

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

Risultato: «» (principale achchhi hoon) contro «» (achchha hoon principale)

Italiano con voce maschile (lorenzo):

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

Risultato: «Sono contento» vs «Sono contenta»

Catena di pensiero per il discorso: ragionamento costituzionale

Utilizzate questo prompt quando volete che il modello mostri il suo ragionamento per problemi complessi:

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.

Nota: se non vuoi che il modello esegua il ragionamento per ogni richiesta, puoi aggiungere un paio di esempi al prompt (vedi gli esempi seguenti).

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)

Uso eccessivo delle frasi suggerite

Nova Sonic 2 è più sensibile ai suggerimenti di frasi rispetto a Sonic 1. Questa maggiore sensibilità non è intrinsecamente buona o cattiva, dipende dal caso d'uso. Se desideri un fraseggio coerente e prevedibile, questo può essere utile. Tuttavia, se si desidera una variazione più naturale, gli elenchi di frasi esplicite possono portare a un uso eccessivo.

Se includi istruzioni con elenchi espliciti di frasi, il modello li utilizzerà molto frequentemente:

Esempio 1 - Frasi di enfasi:

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."

Esempio 2 - Riempitivi conversazionali:

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.

Raccomandazione

- Se desideri una formulazione coerente: gli elenchi di frasi esplicite funzionano bene in Sonic 2 per creare risposte prevedibili e in linea con il marchio.
- Se desideri una variazione naturale: evita di fornire elenchi espliciti di frasi. Utilizza invece indicazioni generali come «suono naturale e colloquiale» o fornisci esempi semplici.

Approccio migliore: utilizza esempi semplici:

Invece di elencare le frasi, fornisci 1-2 esempi che dimostrino il tono e lo stile desiderati:

Tono naturale e utile

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.

Conciso e diretto

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.

Professionista con empatia

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?

Tecnico ma accessibile

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.
```


Questo approccio mostra al modello il comportamento desiderato senza innescare schemi di frasi ripetitivi, pur mantenendo il controllo sul tono e sullo stile.

Concetti principali

Amazon Nova 2 Sonic utilizza un'architettura di streaming bidirezionale con eventi strutturati per un'intelligenza artificiale conversazionale in tempo reale. La comprensione di questi concetti fondamentali è essenziale per creare applicazioni vocali efficaci.

Ciclo di vita dell'evento

Il diagramma seguente illustra il ciclo di vita completo degli eventi di streaming bidirezionale:



Il ciclo di vita degli eventi di streaming bidirezionale segue uno schema strutturato dall'inizializzazione della sessione al completamento della conversazione. Ogni conversazione include eventi di input (dalla tua applicazione) ed eventi di output (da Amazon Nova 2 Sonic) che interagiscono per creare interazioni vocali naturali.

Sequenza del flusso di eventi

Una conversazione tipica segue questa sequenza di eventi:

1. Inizio sessione: inizializza la sessione di conversazione
2. System Prompt: invia istruzioni di sistema
3. Cronologia chat (opzionale): fornisce il contesto della conversazione
4. Audio Chunks: trasmette in streaming l'input audio dell'utente
5. Inizio del completamento: l'IA inizia l'elaborazione
6. Trascrizioni ASR (USER) - Trascrizione vocale dell'utente
7. Utilizzo dello strumento (opzionale): l'IA richiede l'esecuzione dello strumento
8. Gestione degli utensili (opzionale): elabora e restituisce i risultati degli utensili
9. Trascrizione (ASSISTENTE) - SPECULATIVA - Risposta preliminare dell'IA
10. Audio Chunks - Uscita audio AI in streaming
11. Trascrizione (ASSISTENTE) - FINALE - Trascrizione finale della risposta AI
12. Content End Audio: segna la fine del contenuto audio
13. Prompt End: indica il completamento dell'elaborazione del prompt
14. Fine sessione: chiude la conversazione

Gestione degli eventi di input con l'API bidirezionale

L'API di streaming bidirezionale utilizza un'architettura basata sugli eventi con eventi di input e output strutturati. La comprensione del corretto ordine degli eventi è fondamentale per implementare applicazioni conversazionali di successo e mantenere lo stato di conversazione corretto durante le interazioni.

Panoramica di

La conversazione di Nova Sonic segue una sequenza di eventi strutturata. Si inizia inviando un evento `sessionStart` che contiene i parametri di configurazione dell'inferenza, come i limiti di

temperatura e token. Successivamente, si invia `promptStart` per definire il formato dell'output audio e le configurazioni degli strumenti, assegnando un identificatore `promptName` univoco che deve essere incluso in tutti gli eventi successivi.

Per ogni tipo di interazione (prompt di sistema, audio e così via), seguite uno schema in tre parti: `contentStart` da utilizzare per definire il tipo di contenuto e il ruolo del contenuto (`SYSTEM`, `USER`, `ASSISTANT`, `SYSTEM_SPEECH`) `TOOL`, quindi fornite l'evento di contenuto effettivo e terminate con `contentEnd` la chiusura del segmento. L'evento `contentStart` specifica se stai inviando i risultati dello strumento, lo streaming audio o un prompt di sistema. L'evento `contentStart` include un identificatore `contentName` univoco.

Cronologia delle conversazioni

Una cronologia delle conversazioni può essere inclusa una sola volta, dopo il prompt di sistema e prima dell'inizio dello streaming audio. Segue lo stesso schema `contentStart/textInput/contentEnd`. I ruoli `USER` e `ASSISTANT` devono essere definiti nell'evento `contentStart` per ogni messaggio storico. Ciò fornisce un contesto essenziale per la conversazione attuale, ma deve essere completato prima che inizi qualsiasi nuovo input da parte dell'utente.

Streaming audio

Lo streaming audio funziona con un campionamento continuo del microfono. Dopo l'invio di un `contentStart` iniziale, i frame audio (circa 32 ms ciascuno) vengono acquisiti direttamente dal microfono e inviati immediatamente come eventi `audioInput` utilizzando lo stesso `contentName`. Questi campioni audio devono essere trasmessi in streaming in tempo reale man mano che vengono acquisiti, mantenendo la naturale cadenza di campionamento del microfono per tutta la conversazione. Tutti i frame audio condividono un singolo container di contenuti fino al termine della conversazione e alla sua chiusura esplicita.

Chiusura della sessione


Dopo che la conversazione è terminata o deve essere interrotta, è fondamentale chiudere correttamente tutti gli stream aperti e terminare la sessione nella sequenza corretta. Per terminare correttamente una sessione ed evitare perdite di risorse, devi seguire una sequenza di chiusura specifica:

- Chiudi tutti gli streaming flussi audio aperti con l'evento `contentEnd`.
- Invia un evento `promptEnd` che fa riferimento al `promptName` originale.

- Invia l'evento `sessionEnd`.

Saltare uno qualsiasi di questi eventi di chiusura può portare a conversazioni incomplete o alla creazione di risorse orfane.

Questi identificatori creano una struttura gerarchica: i `promptName` collegano tutti gli eventi di conversazione, mentre ciascun `contentName` segna i confini di blocchi di contenuto specifici. Questa gerarchia garantisce che il modello mantenga il contesto corretto durante l'interazione.



Flusso di eventi di input

La struttura del flusso di eventi di input è riportata in questa sezione.

1. RequestStartEvent (Inizio sessione)

L'evento di inizio della sessione inizializza la conversazione con la configurazione dell'inferenza e le impostazioni di rilevamento dei turni.

Configurazione dell'inferenza:

- `maxTokens`: numero massimo di token da generare nella risposta
- `topP`: Parametro di campionamento del nucleo (da 0,0 a 1,0) per il controllo della casualità

- **temperature**: Controlla la casualità nella generazione (da 0,0 a 1,0)

Configurazione Turn Detection: il `endpointingSensitivity` parametro controlla la velocità con cui Nova Sonic rileva quando un utente ha finito di parlare:

- **HIGH**: Rileva rapidamente le pause, permettendo risposte più rapide, ma può spegnere gli altoparlanti più lenti
- **MEDIUM**: sensibilità bilanciata per la maggior parte degli scenari di conversazione (impostazione predefinita consigliata)
- **LOW**: Attende più a lungo prima di rilevare la fine del discorso, preferibile per chi parla in modo riflessivo o titubante

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

Esempio:

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

```

    }
  }
}

```

2. PromptStartEvent

L'evento prompt start definisce la configurazione della conversazione, inclusi i formati di output, la selezione vocale e gli strumenti disponibili.

Per un elenco delle voci disponibili IDs, consulta [Supporto linguistico e funzionalità multilingue](#)

```

{
  "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

Testo

L'evento di avvio del contenuto testuale viene utilizzato per i prompt di sistema, la cronologia delle conversazioni e l'immissione di testo intermodale.

Parametro interattivo:

- `true`: Abilita l'input intermodale, permettendo l'invio di messaggi di testo durante una sessione vocale attiva
- `false`: immissione di testo standard per le istruzioni di sistema e la cronologia delle conversazioni

Tipi di ruolo:

- `SYSTEM`: istruzioni e istruzioni di sistema
- `USER`: messaggi utente nella cronologia delle conversazioni o nell'input intermodale
- `ASSISTANT`: risposte dell'assistente nella cronologia delle conversazioni
- `SYSTEM_SPEECH`: controlla la formattazione della trascrizione per la commutazione di codice in hindi (script) 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"
      }
    }
  }
}

```

```
}
```

Esempio - System Prompt:

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

Esempio: input intermodale:

```
{
  "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"
        }
    }
}

```

Strumento

```

{
  "event": {
    "contentStart": {
      "promptName": "string", // same unique identifier from promptStart event
      "contentName": "string", // unique identifier for the content block
      "interactive": false,
      "type": "TOOL",
      "role": "TOOL",
      "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": {}
  }
}

```

Gestione degli eventi di output con l'API bidirezionale

Quando il modello Amazon Nova Sonic risponde, segue una sequenza di eventi strutturata. Il flusso inizia con un evento `completionStart` che contiene identificatori univoci come `sessionId`, `promptName` e `completionId`. Questi identificatori sono coerenti per tutto il ciclo di risposta e uniscono tutti gli eventi di risposta successivi.

Panoramica di

Ogni tipo di risposta segue uno schema coerente in tre parti: `contentStart` definisce il tipo e il formato del contenuto, l'effettivo evento del contenuto e `contentEnd` chiude il segmento. Di norma, la risposta include più blocchi di contenuto in sequenza: riconoscimento vocale automatico (ASR), trascrizione (ciò che ha detto l'utente), uso opzionale di strumenti (quando sono necessarie informazioni esterne), risposta testuale (ciò che il modello intende dire) e risposta audio (l'output vocale).

Tipi di contenuto della risposta

Trascrizione ASR

La trascrizione ASR viene visualizzata per prima e consente al modello di comprendere il discorso dell'utente con `role: "USER"` e `"additionalModelFields": "{ \"generationStage\": \"FINAL\" }"` nel `contentStart`.

Uso dello strumento

Quando il modello ha bisogno di dati esterni, invia eventi relativi allo strumento con nomi e parametri specifici degli strumenti.

Risposta testuale

La risposta testuale fornisce un'anteprima del contenuto vocale pianificato con `role`:

"ASSISTANT" e "additionalModelFields": "{\\"generationStage\\":\\"SPECULATIVE\\"}"

Risposta audio

La risposta audio fornisce quindi blocchi vocali codificati in base 64 che condividono lo stesso `contentId` durante lo streaming.

Barge-In Support

Durante la generazione audio, Amazon Nova Sonic supporta un flusso di conversazione naturale tramite la sua funzionalità di barge-in. Quando un utente interrompe Amazon Nova Sonic mentre sta parlando, Nova Sonic interrompe immediatamente la generazione vocale, passa alla modalità di ascolto e invia una notifica di contenuto in cui si indica che è avvenuta un'interruzione. Poiché Nova Sonic funziona più velocemente rispetto al tempo reale, parte dell'audio potrebbe essere già stata trasmessa ma non ancora riprodotta. La notifica dell'interruzione consente all'applicazione client di cancellare la coda audio e interrompere immediatamente la riproduzione, creando un'esperienza di conversazione reattiva.

Trascrizione finale

Una volta completata la generazione audio (o interrotta tramite barge-in), Amazon Nova Sonic fornisce una risposta testuale aggiuntiva che contiene una trascrizione a livello di frase di ciò che è stato effettivamente pronunciato. Questa risposta testuale include un evento `contentStart` con `role`: "ASSISTANT" e "additionalModelFields": "{\\"generationStage\\":\\"FINAL\\"}"

Monitoraggio dell'utilizzo


Durante la gestione della risposta, vengono inviati eventi `usageEvent` per monitorare il consumo di token. Questi eventi contengono metriche dettagliate sui token di input e output (sia vocali che testuali) e i relativi totali cumulativi. Ciascun `usageEvent` mantiene gli stessi eventi `sessionId`, `promptName` e `completionId` degli altri eventi nel flusso di conversazione. La sezione dei dettagli

fornisce sia le modifiche incremental (delta) che i totali attuali dell'utilizzo dei token, consentendo un monitoraggio preciso dell'utilizzo durante la conversazione.

Completamento

Il modello invia un evento `completionEnd` con gli identificatori originali e un `stopReason` che indica come è terminata la conversazione. Questa gerarchia di eventi garantisce che l'applicazione possa monitorare quali parti della risposta vanno combinate tra loro e le elabora di conseguenza, mantenendo il contesto della conversazione per più turni.

Il flusso di eventi di output inizia entrando nella fase di generazione della risposta. Parte dal riconoscimento vocale automatico, seleziona uno strumento da utilizzare, trascrive il contenuto vocale, genera audio, finalizza la trascrizione e termina la sessione.



Flusso di eventi in uscita

La struttura del flusso di eventi di output è descritta in questa sezione.

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

Il barge-in consente agli utenti di interrompere l'assistente AI mentre sta parlando, proprio come nelle conversazioni umane naturali. Invece di aspettare che l'assistente finisca, gli utenti possono intervenire fornendo nuove informazioni, correggere o chiarire la dichiarazione precedente, reindirizzare la conversazione su un argomento diverso o semplicemente interrompere l'assistente quando hanno sentito abbastanza. Questo crea un'esperienza di conversazione più naturale e reattiva.

Il diagramma seguente illustra l'intero flusso di conversazione introduttivo:



In che modo Amazon Nova 2 Sonic gestisce i barge-in

Amazon Nova 2 Sonic è progettato per gestire le interruzioni con garbo. Quando l'utente inizia a parlare durante una risposta, il sistema smette immediatamente di generare la risposta corrente, mantiene il contesto della conversazione completo, invia un segnale di interruzione al client e inizia a elaborare il nuovo input dell'utente.

Conservazione del contesto: anche in caso di interruzione, Nova Sonic ricorda ciò che è stato detto prima dell'interruzione, l'argomento discusso, la cronologia delle conversazioni e qualsiasi contesto rilevante dei turni precedenti. Questo assicura che la conversazione rimanga coerente e naturale.

Requisiti di implementazione lato client

Sebbene Amazon Nova 2 Sonic gestisca il barge-in lato server, devi implementare la logica lato client per un'esperienza completa.

La sfida della coda audio: la generazione dell'audio è più veloce della velocità di riproduzione. Ciò significa che:

- Nova Sonic genera rapidamente blocchi audio
- Il tuo client riceve e mette in coda questi blocchi
- Il client li riproduce alla normale velocità di conversazione
- Quando si verifica un barge-in, l'audio è già in coda per la riproduzione

Logica lato client richiesta: l'applicazione deve gestire quattro passaggi chiave:

1. Rileva il segnale di interruzione: ascolta l'evento di interruzione di Nova Sonic e reagisci immediatamente quando viene ricevuto.
2. Interrompi la riproduzione corrente: mette in pausa l'audio attualmente in riproduzione e interrompe l'audio a metà riproduzione.
3. Cancella la coda audio: rimuovi tutti i blocchi audio in coda ed elimina l'audio bufferizzato dalla risposta interrotta.
4. Avvia nuovo audio: inizia a riprodurre l'audio appena ricevuto e riprendi il normale flusso di riproduzione.

Controllabilità a turni

L'assunzione di turni è un aspetto fondamentale della conversazione naturale. Amazon Nova 2 Sonic offre un controllo preciso su quando l'intelligenza artificiale interviene a turno per parlare attraverso il parametro `turnDetectionConfiguration`. Ciò consente di ottimizzare il flusso di conversazione per diversi casi d'uso, bilanciando la reattività con la precisione. Il parametro `EndPointingSensitivity` controlla la velocità con cui Amazon Nova 2 Sonic rileva la fine del turno di un utente e inizia a rispondere. Questa impostazione influisce sia sulla latenza delle risposte che sulla probabilità di interrompere gli utenti che stanno ancora parlando.

Configurazione dell'API

Configura la sensibilità al rilevamento dei turni nell'evento `SessionStart`:

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

Livelli di sensibilità

Il parametro `EndPointingSensitivity` accetta tre valori: `HIGH`, `MEDIUM` e `LOW`. Ogni livello bilancia la velocità di risposta con il rischio di interrompere gli utenti che stanno ancora parlando.

HIGH (ELEVATO)

Tempo di risposta più rapido, ottimizzato per la latenza. Nova Sonic risponde il più rapidamente possibile dopo aver rilevato la fine del discorso. Durata della pausa: 1,5 secondi. Ideale per domande e risposte rapide, command-and-control applicazioni e interazioni urgenti.

MEDIO

Approccio bilanciato con tempi di risposta moderati. Riduce i falsi positivi mantenendo la reattività. Durata della pausa: 1,75 secondi. Ideale per conversazioni generiche, assistenza clienti con domande complesse e discussioni a più turni.

BASSO

Tempo di risposta più lento con la massima pazienza. Nova Sonic attende più a lungo prima di rispondere, riducendo al minimo le interruzioni degli utenti che si fermano mentre pensano. Durata della pausa: 2 secondi. Ideale per conversazioni ponderate, utenti anziani o con problemi di linguaggio e per la risoluzione di problemi complessi.

Riferimento alla durata della pausa

Livello di sensibilità	Durata della pausa (secondi)
Alta (veloce)	1.5
Media	1,75
Basso (lento)	~2,0

Ingresso intermodale

Amazon Nova 2 Sonic ora supporta l'input intermodale, che consente di inviare messaggi di testo oltre all'input vocale durante una sessione di conversazione. Sebbene la voce rimanga la modalità di interazione principale, l'immissione di testo offre flessibilità per gli scenari in cui la digitazione è più comoda o appropriata.

Streaming continuo richiesto: l'input intermodale richiede una sessione di streaming attiva per funzionare correttamente. La sessione deve mantenere lo streaming continuo come una normale sessione vocale, altrimenti verranno applicati i timeout di sessione standard e la connessione verrà interrotta.

I livelli di sensibilità nell'immissione di testo intermodale sono utili per scenari come:

- Integrazione delle app lato client (web e mobile): consente agli utenti di interagire con l'applicazione utilizzando sia testo che voce, supportando esperienze multimodali senza interruzioni.

- Caso d'uso odel-start-first «M»: è possibile inviare un messaggio di testo immediatamente dopo l'inizio della sessione per richiedere alla modella di iniziare a parlare.
- Guida del modello durante la chiamata asincrona dello strumento: quando viene attivato un evento toolUse e il sistema inizia a elaborare le chiamate allo strumento, il client può inviare un messaggio di testo a Sonic per fornire una risposta naturale durante l'attesa, ad esempio «Aspetta un secondo mentre elaboro le tue informazioni. Nel frattempo, c'è qualcos'altro che posso fare per aiutarvi?»
- Integrazione DTMF per la telefonia: il cliente utilizza la tastiera del telefono per inserire informazioni sensibili (come i numeri delle carte di credito). Nota: Amazon Nova Sonic non elabora i toni DTMF in modo nativo. Per supportare l'input DTMF, il sistema deve rilevare i toni, convertirli in testo (ad esempio «1234») e inviarli a Nova 2 Sonic.

Come funziona

L'ingresso intermodale utilizza una sequenza di tre eventi simile all'ingresso audio:

1. Content Start Event: segnala l'inizio dell'immissione del testo
2. Evento di immissione di testo: contiene il messaggio di testo effettivo
3. Evento finale del contenuto: segnala il completamento dell'immissione del testo

Tutti e tre gli eventi devono utilizzare gli stessi promptName e contentName per mantenere la sequenza. È necessario generare un nuovo UUID per ContentName ogni volta che si invia un input di testo per garantire il corretto monitoraggio delle conversazioni a turni multipli.

Struttura degli eventi

1. Evento Content Start

Avvia la sequenza di immissione del testo con i dettagli di configurazione:

```
{
  "event": {
    "contentStart": {
      "promptName": "<prompt_name>",
      "contentName": "<new_content_name>",
      "role": "USER",
      "type": "TEXT",
      "interactive": true,
```



```
    "textInputConfiguration": {  
      "mediaType": "text/plain"  
    }  
  }  
}  
}
```

Parametri chiave:

- **promptName** Avvia la sequenza di immissione del testo con i dettagli di configurazione: ----sep----:Il nome del prompt di conversazione (coerente per tutta la sessione)
- **contentName**: Un identificatore univoco per questo input di testo (genera un nuovo UUID per ogni messaggio)
- **role**: impostato per indicare l'input dell'"USER"utente
- **type**: impostato su "TEXT" per l'immissione di testo
- **interactive**: impostato per true abilitare la modalità interattiva
- **mediaType**: impostato su "text/plain" per il contenuto di testo semplice

2. Evento di immissione di testo

Contiene il contenuto effettivo del messaggio di testo:

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

Parametri chiave:

- **promptName**: deve corrispondere al valore di Content Start Event
- **contentName**: deve corrispondere al valore di Content Start Event
- **role**: la stringa del messaggio di testo

3. Evento finale del contenuto

Segnala il completamento dell'immissione del testo:

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

Parametri chiave:

- **promptName**: Deve corrispondere al valore degli eventi precedenti
- **contentName**: Deve corrispondere al valore degli eventi precedenti

Supporto linguistico e funzionalità multilingue

Amazon Nova 2 Sonic offre una selezione diversificata di voci in più lingue, consentendoti di creare applicazioni di intelligenza artificiale conversazionale naturali e culturalmente appropriate per i tuoi utenti. Ogni lingua offre opzioni vocali dal suono femminile e maschile.

La tabella seguente elenca tutte le voci disponibili e le relative lingue locali:

Lingua	Locale	Voice ID dal suono femminile	Voice ID dal suono maschile
Inglese (Stati Uniti)	it-IT	tiffany	matthew
Inglese (Regno Unito)	en-GB	amy	-
Inglese (Australia)	en-AU	Olivia	-
Inglese (India)	en-IN	kiara	arjun
Francese	fr-FR	ambre	florian
Italiano	it-IT	beatrice	lorenzo

Lingua	Locale	Voice ID dal suono femminile	Voice ID dal suono maschile
Tedesco	de-DE	tina	lennart
Spagnolo (Stati Uniti)	es-US	lupe	carlos
Portoghese	pt-BR	carolina	leone
Hindi	hi-IN	kiara	arjun

Struttura degli eventi che utilizza le voci nell'applicazione

È possibile specificare l'ID vocale in `audioOutputConfiguration` quando si avvia un prompt nell'`promptStart`evento:

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

Supporto multilingue

Amazon Nova 2 Sonic offre potenti funzionalità multilingue che consentono conversazioni naturali in più lingue. Il servizio supporta sia voci poliglote (che parlano più lingue) che il cambio di codice (combinazione di lingue all'interno della stessa frase), consentendoti di creare applicazioni conversazionali veramente globali.

TIFFANY (en-US, femmina) e MATTHEW (en-US, maschio) sono voci poliglote uniche che possono parlare tutte le lingue supportate:

1. Italiano
2. Francese
3. Italiano
4. Tedesco
5. Spagnolo
6. Portoghese
7. Hindi

Ciò rende Tiffany e Matthew ideali per le applicazioni che devono passare da una lingua all'altra senza interruzioni.

Gestione della cronologia chat


Le risposte di Amazon Nova 2 Sonic includono trascrizioni ASR (Automatic Speech Recognition) per le voci degli utenti e degli assistenti. La memorizzazione della cronologia chat è una buona pratica, non solo per scopi di registrazione, ma anche per riprendere le sessioni quando la connessione viene chiusa inaspettatamente. Ciò consente al client di inviare il contesto a Nova Sonic per continuare la conversazione senza interruzioni.

Per ulteriori informazioni sulla gestione della cronologia chat, consulta le seguenti risorse:

1. [Registrazione della cronologia chat](#)
2. [Ripresa delle conversazioni](#)

Invio della cronologia chat

La cronologia delle conversazioni può essere inclusa una sola volta, dopo la richiesta di sistema/ riconoscimento vocale e prima dell'inizio dello streaming audio. La cronologia complessiva della chat non può superare i 40 KB. Il diagramma seguente mostra quando la cronologia chat viene trasmessa durante il ciclo di vita dell'evento:



Ogni messaggio storico richiede tre eventi: `contentStart`, e. `textInput` `contentEnd`

Schema degli eventi per messaggio:

- `contentStart`- Definisce il ruolo e la configurazione del messaggio

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

- `textInput`- Contiene il contenuto effettivo del messaggio. Un `TextInput` non può essere più grande di 1 KB. In tal caso, suddividilo in più `TextInput` nello stesso blocco di contenuto. Se la conversazione supera i 40 KB, taglia la cronologia generale della chat.

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

- `contentEnd`- Segna la fine del messaggio

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

```
}  
}
```

Ripeti questi tre eventi per ogni messaggio nella cronologia chat, alternando i ruoli UTENTE e ASSISTENTE.

Considerazioni importanti:

- La cronologia chat può essere inclusa solo una volta per sessione
- La cronologia chat deve essere inviata dopo la richiesta del sistema e prima dell'inizio dello streaming audio
- Tutti i messaggi storici devono essere inviati prima di iniziare lo streaming audio
- Ogni messaggio deve specificare il ruolo USER o ASSISTANT
- Utilizza il contenuto della trascrizione memorizzato dagli eventi TextOutput come valore del contenuto in TextInput

Ricezione di trascrizioni ASR

Durante una conversazione, Amazon Nova 2 Sonic invia trascrizioni ASR tramite eventi di output. Ogni trascrizione viene fornita come una sequenza di tre eventi: contentStart, textOutput e contentEnd.

Esempio: trascrizione vocale dell'utente:

1. ContentStart: indica l'inizio di una trascrizione:

```
{  
  "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**: contiene il contenuto effettivo della trascrizione:

```

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

```

3. **contentEnd** - Segna la fine della trascrizione:

```

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

```

Lo stesso schema a tre eventi si applica sia ai ruoli **USER** che **ASSISTANT**. Estrai il **content** campo dall'**textOutput** evento e il **role** campo dall'**contentStart** evento per creare la cronologia chat.

Best practice

Memorizza sempre la cronologia chat per abilitare:

- Riprese delle sessioni su diversi dispositivi

- Registrazione e controllo delle conversazioni
- Conservazione del contesto per le interazioni successive

Importante: quando salvate la cronologia delle chat, utilizzate gli output di testo basati sul relativo `GenerationStage`:

- Speculativo: un'anteprima di ciò che Nova 2 Sonic intende dire, generato prima dell'inizio della sintesi audio
- Finale: l'effettiva trascrizione a livello di frase di ciò che è stato pronunciato nella risposta audio

Salva sempre il testo FINALE in uscita nella cronologia chat, poiché rappresenta la registrazione accurata della conversazione.

Esempio di output FINALE (salvalo nella cronologia chat):

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

Esempio di output SPECULATIVO (anteprima opzionale, non per la cronologia):

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

Configurazione dello strumento

Amazon Nova 2 Sonic supporta l'uso di strumenti (noto anche come chiamata di funzione), che consente al modello di richiedere informazioni o azioni esterne durante le conversazioni,


come chiamate API, interrogazioni di database o funzioni di codice personalizzate. Ciò consente all'assistente vocale di eseguire azioni, recuperare informazioni e integrarsi con servizi esterni in base alle richieste degli utenti.

Nova 2 Sonic offre una chiamata asincrona degli strumenti, che consente all'intelligenza artificiale di continuare a conversare in modo naturale mentre gli strumenti funzionano in background, creando un'esperienza utente più fluida e reattiva.

Di seguito sono riportati i passaggi semplificati sull'utilizzo degli strumenti:

1. Definizione degli strumenti: specifica gli strumenti disponibili con i relativi parametri nell'evento PromptStart
2. L'utente parla: l'utente fa una richiesta che richiede uno strumento (ad esempio, «Che tempo fa a Seattle?»)»
3. Invocazione dello strumento: Nova 2 Sonic riconosce la necessità e invia un evento toolUse
4. Esegui strumento: l'applicazione esegue lo strumento e restituisce risultati
5. Generazione di risposte: Nova 2 Sonic incorpora i risultati nella sua risposta vocale

Il diagramma seguente illustra come funziona l'uso degli strumenti:



Definizione degli strumenti

Gli strumenti vengono definiti utilizzando uno schema JSON che ne descrive lo scopo, i parametri e gli input previsti.

Di seguito sono riportati i componenti e le spiegazioni della definizione degli strumenti:

- **Nome:** identificatore univoco dello strumento (usa `snake_case`)
- **Descrizione:** spiegazione chiara di cosa fa lo strumento; aiuta l'intelligenza artificiale a decidere quando utilizzarlo
- **InputSchema:** schema JSON che definisce i parametri accettati dallo strumento
- **Proprietà:** parametri individuali con tipi e descrizioni
- **Obbligatorio:** matrice di nomi di parametri che devono essere forniti

Esempio di definizione dell'utensile

Ecco una semplice definizione dello strumento meteorologico

```
{
  "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"]
      }
    }
  }
}
```

```
}
```

Configurazione degli strumenti in PromptStart

La configurazione dello strumento viene passata a Nova 2 Sonic nell'`promptStart` evento insieme alle impostazioni di output audio e di testo:

```
{
  "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": {}
  }
}

```

Parametri di scelta dello strumento

Nova 2 Sonic supporta tre parametri di scelta degli utensili per controllare quando e quali strumenti vengono utilizzati. Specificate il parametro ToolChoice nella configurazione dello strumento:

- **Automatico** (impostazione predefinita): il modello decide se sono necessari utensili e, se necessario, può richiamare più strumenti. Fornisce la massima flessibilità.
- **Qualsiasi**: assicura che almeno uno degli strumenti disponibili venga richiamato all'inizio della risposta, con il modello che seleziona quello più appropriato. Utile quando si dispone di più basi di conoscenza o strumenti e si desidera garantire che ne venga utilizzato uno.
- **Strumento**: forza uno strumento con nome specifico a essere chiamato esattamente una volta all'inizio della risposta. Ad esempio, se specificate uno strumento della knowledge base, il modello lo interrogherà prima di rispondere, indipendentemente dal fatto che lo ritenga necessario.

Esempi di scelta degli strumenti

Auto (impostazione predefinita)

```

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

```

Qualsiasi:

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

Strumento specifico:

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

Ricezione ed elaborazione degli eventi relativi all'utilizzo dello strumento

Quando Amazon Nova 2 Sonic determina che è necessario uno strumento, invia un `toolUse` evento contenente:

1. `toolUseID`: identificatore univoco per la chiamata di questo strumento
2. `ToolName`: il nome dello strumento da eseguire
3. `Contenuto`: stringa JSON contenente i parametri estratti dalla richiesta dell'utente
4. `sessionId`: identificatore della sessione corrente
5. `Ruolo`: impostato su «TOOL» per gli eventi di utilizzo dello strumento

Esempio di evento di utilizzo dello strumento

```
{  
  "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>"  
    }  
  }  
}
```

```
}  
}
```

Fasi di elaborazione

1. Ricevi l'evento ToolUse da Nova 2 Sonic
2. Estrai il nome e i parametri dello strumento dall'evento
3. Esegui la logica dello strumento (chiamata API, interrogazione del database e così via)
4. Restituisci il risultato utilizzando un evento ToolResult

Evento di esempio ToolResult

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

Best practice

- **Descrizioni chiare:** scrivete descrizioni dettagliate degli strumenti per aiutare Nova 2 Sonic a capire quando utilizzare ogni strumento.
- **Convalida i parametri:** convalida sempre i parametri dello strumento prima dell'esecuzione per evitare errori. Definite i parametri dello strumento utilizzando lo schema JSON appropriato con tipi di dati strutturati (come enumerazioni, numeri o valori booleani) anziché stringhe aperte, ove possibile.
- **Gestione degli errori:** restituisce messaggi di errore significativi negli eventi ToolResult quando gli strumenti falliscono.
- **Esecuzione asincrona:** sfrutta la chiamata asincrona agli strumenti per mantenere il flusso di conversazione.
- **Denominazione degli strumenti:** utilizza nomi descrittivi e orientati all'azione (come `get_weather`, `search_database`, `send_email`).

Chiamata asincrona degli strumenti


A differenza della tradizionale chiamata sincrona degli strumenti, in cui l'intelligenza artificiale attende silenziosamente i risultati degli strumenti, l'approccio asincrono di Amazon Nova 2 Sonic consente di:

- Continua ad accettare l'input dell'utente mentre gli strumenti sono in esecuzione
- Rispondi a nuove domande senza attendere i risultati degli strumenti in sospeso
- Gestisci più chiamate allo strumento contemporaneamente
- Mantieni un flusso di conversazione naturale senza pause imbarazzanti
- Non è richiesta alcuna configurazione aggiuntiva. La chiamata asincrona degli strumenti funziona immediatamente.

Come funziona

Quando Nova 2 Sonic effettua una chiamata telefonica, non mette in pausa la conversazione. Al contrario, continua ad ascoltare e a rispondere in modo naturale fino all'arrivo dello strumento.


Asynchronous Tool Calling Flow



Gestione delle interruzioni da parte degli utenti

Se un utente modifica la richiesta durante l'esecuzione di uno strumento, Nova 2 Sonic la gestisce in modo intelligente senza annullare le chiamate agli strumenti in sospeso.

Async Tool Calling with User Interruption



Scenario di esempio

```

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]
  
```

Come funziona

I risultati dello strumento vengono sempre forniti: quando una chiamata allo strumento viene completata, il risultato viene sempre inviato al modello, anche se l'utente ha modificato la richiesta. Il modello utilizza le sue capacità di ragionamento per determinare come gestire le informazioni.

Elaborazione sensibile al contesto: il modello comprende il contesto della conversazione ed è in grado di gestire in modo appropriato i risultati degli strumenti obsoleti. Esempio:

- Se l'utente dice «grazie» dopo aver cambiato idea, il modello necessita comunque dei risultati originali come contesto
- Se l'utente modifica la richiesta, il modello può riconoscere i risultati originali mentre si concentra sulla nuova richiesta

Nessuna cancellazione automatica: il sistema non annulla o ignora automaticamente le chiamate agli strumenti in base all'input di un nuovo utente. Ciò garantisce che il modello disponga di informazioni complete per prendere decisioni intelligenti su come rispondere.

Integrazioni

Amazon Nova 2 Sonic può essere integrato con vari framework e piattaforme per creare applicazioni di intelligenza artificiale conversazionale. Queste integrazioni forniscono componenti predefiniti e semplificati per casi d'uso comuni. APIs

Agenti Strands

Strands Agents è un SDK semplice ma potente che adotta un approccio basato su modelli alla creazione e all'esecuzione di agenti AI. Da semplici assistenti conversazionali a complessi flussi di lavoro autonomi, dallo sviluppo locale all'implementazione in produzione, Strands Agents si adatta alle vostre esigenze.

[Per una documentazione completa sul framework Strands, consulta la documentazione ufficiale di Strands.](#)

Strands BidiAgent fornisce interazioni audio e testuali in tempo reale attraverso connessioni di streaming persistenti. A differenza dei modelli tradizionali di richiesta-risposta, questo agente mantiene conversazioni di lunga durata con supporto per interruzioni, elaborazione simultanea e risposte audio continue.

Prerequisiti:

- Python 3.8 o successivo installato
- Credenziali per AWS configurazioni con accesso ad Amazon Bedrock
- Familiarità di base con la sintassi di Python async/await

Esempio di codice:

Esempio di codice

Installation (Installazione):

Installa i pacchetti richiesti:

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

Esegui questo esempio:

```
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. Importa: modelli richiesti

```

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:** La classe di agenti principale che orchestra le conversazioni bidirezionali
- **BidiAudioIO:** gestisce l'ingresso e l'uscita audio per le interazioni vocali
- **BidiTextIO:** fornisce un output di testo per trascrizioni e risposte
- **BidiNovaSonicModel** L'involucro del modello Nova 2 Sonic
- **Calcolatrice:** uno strumento predefinito per operazioni matematiche

2. Configura I/O audio e di testo

```

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

```

L' **BidiAudioIO** gestisce l'ingresso del microfono e l'uscita degli altoparlanti, mentre l' **BidiTextIO** visualizza le trascrizioni e le risposte del testo nella console.

3. Inizializza il modello

```

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

```

Create un'istanza del modello Nova Sonic. Il parametro `region` specifica la AWS regione in cui viene distribuito il modello.

4. Crea ed esegui l'agente

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

L'agente viene creato con:

- Modello: Il modello Nova 2 Sonic da utilizzare
- Strumenti: elenco degli strumenti che l'agente può chiamare (come la calcolatrice)
- Ingressi: ingresso audio dal microfono
- Uscite: uscita audio per gli altoparlanti e uscita di testo per la console


Integrazioni del framework

Amazon Nova 2 Sonic può essere integrato con vari framework e piattaforme per creare applicazioni vocali sofisticate. I seguenti esempi illustrano i modelli di integrazione con i framework più diffusi.

Amazon Bedrock AgentCore

Amazon Bedrock AgentCore fornisce un ambiente di runtime gestito per la distribuzione di applicazioni Nova 2 Sonic con sicurezza e scalabilità di livello aziendale. AgentCore semplifica la distribuzione di applicazioni di intelligenza artificiale vocale in tempo reale gestendo l'infrastruttura, l'autenticazione e la connettività. WebSocket

AgentCore Architecture



Caratteristiche principali:

- **Streaming bidirezionale:** supporto nativo per l'interfaccia di streaming full-duplex di Nova Sonic con elaborazione degli eventi in tempo reale e comunicazione a bassa latenza.
- **WebSocket infrastruttura:** WebSocket server pronti per la produzione con scalabilità automatica, gestione delle connessioni e ripristino degli errori.
- **Implementazione di container:** distribuisce le applicazioni Nova Sonic come contenitori nell'infrastruttura gestita con scalabilità orizzontale e controllo delle versioni indipendente.
- **Sicurezza aziendale:** autenticazione granulare tramite IAM e SigV4, isolamento VPC e registrazione di controllo completa.

L'architettura mostra come le applicazioni client si connettono a Runtime tramite l'autenticazione SigV4. AgentCore WebSocket L'ambiente containerizzato include il WebSocket server, la logica dell'applicazione e il client Nova Sonic, tutti comunicanti con Nova Sonic tramite l'API di streaming bidirezionale.

Vantaggi:

- Operazioni semplificate: concentratevi sulla logica delle applicazioni AgentCore gestendo al contempo l'infrastruttura, la scalabilità e l'affidabilità.
- Sicurezza aziendale: funzionalità integrate di autenticazione, autorizzazione e conformità per le implementazioni di produzione.
- Efficienza in termini di costi: paghi solo per ciò che utilizzi con la scalabilità automatica e l'ottimizzazione delle risorse.
- Produttività degli sviluppatori: riduci i tempi di produzione con l' WebSocket infrastruttura gestita e l'implementazione di container.

Casi d'uso


- Assistenti vocali del servizio clienti con autenticazione sicura
- Applicazioni vocali aziendali che richiedono l'integrazione con IAM
- Piattaforme vocali multi-tenant con implementazioni isolate
- Applicazioni vocali che richiedono conformità e audit trail

Per una documentazione dettagliata sulla distribuzione di Nova Sonic con AgentCore, consulta la documentazione di [Amazon AgentCore Bedrock](#).

LiveKit

LiveKit è una piattaforma open source per la creazione di applicazioni audio e video in tempo reale. L'integrazione con Amazon Nova 2 Sonic consente agli sviluppatori di creare interfacce vocali conversazionali senza gestire pipeline audio o protocolli di segnalazione complessi.

[Per esempi di implementazione dettagliati ed esempi di codice, consulta la documentazione sull'integrazione. LiveKit AWS](#)



Come funziona:

- **Livello client:** le applicazioni Web, mobili o desktop si connettono utilizzando LiveKit il client SDKs, che gestisce l'acquisizione audio, lo streaming WebRTC e la riproduzione.
- **LiveKit Server:** funge da hub di comunicazione in tempo reale, gestendo le connessioni WebRTC, instradando i flussi audio e gestendo lo stato della sessione con ottimizzazione a bassa latenza.
- **LiveKit Agente:** agente basato su Python che riceve l'audio dal server, lo elabora tramite il plug-in Nova Sonic e restituisce le risposte. Include funzionalità integrate come il rilevamento dell'attività vocale e la gestione dei turni.
- **Amazon Nova 2 Sonic:** elabora il flusso audio tramite API di streaming bidirezionale, esegue il riconoscimento vocale, la comprensione del linguaggio naturale e genera risposte conversazionali con voce sintetizzata.


Pipecat

Pipecat è un framework per la creazione di applicazioni di intelligenza artificiale conversazionale vocale e multimodale. Fornisce un'architettura modulare basata su pipeline che orchestra più componenti per creare applicazioni vocali intelligenti con Amazon Nova Sonic e altri servizi. AWS

[Per esempi di implementazione dettagliati ed esempi di codice, consulta la documentazione sull'integrazione. PipeCat AWS](#)

Caratteristiche principali:

- Architettura della pipeline: framework modulare basato su Python per la composizione di componenti di intelligenza artificiale vocale tra cui ASR, NLU, TTS e altri.
- Flussi Pipecat: framework di gestione dello stato per la creazione di logiche conversazionali complesse e l'esecuzione di strumenti.
- Supporto WebRTC: integrazione integrata con Daily e altri provider WebRTC per lo streaming audio in tempo reale.
- AWS Integrazione: supporto nativo per Amazon Bedrock, Amazon Transcribe e Amazon Polly.



L'architettura include:

- Trasporto WebRTC: streaming audio in tempo reale tra dispositivi client e server delle applicazioni.
- Rilevamento dell'attività vocale (VAD): Silero VAD con rilevamento vocale configurabile e soppressione del rumore.
- Riconoscimento vocale: Amazon Transcribe per una conversione accurata e in tempo reale. speech-to-text
- Comprensione del linguaggio naturale: Amazon Nova Pro on Bedrock con inferenza ottimizzata per la latenza.
- Esecuzione dello strumento: Pipecat Flows per l'integrazione delle API e le chiamate ai servizi di backend.
- Generazione di risposte: Amazon Nova Pro per risposte coerenti e sensibili al contesto.
- Text-to-speech: Amazon Polly con voci generative per un output vocale realistico.


Implementa su AWS

Implementa le tue applicazioni Nova Sonic AWS utilizzando l'infrastruttura come codice con AWS CDK (Cloud Development Kit). Questo approccio offre implementazioni ripetibili e controllate dalla versione con le migliori pratiche integrate.

Opzioni di implementazione

- Amazon ECS (Elastic Container Service): orchestrazione di container completamente gestita con integrazione Application Load Balancer, auto-scaling ed esecuzione Fargate senza server.
- Amazon EKS (Elastic Kubernetes Services): Kubernetes gestito per orchestrazione complessa, reti avanzate, implementazioni multiregionali e un ampio ecosistema di strumenti.
- AWS CDK: CDK consente di definire l'infrastruttura cloud utilizzando linguaggi di programmazione familiari. AWS

[Per un esempio completo e pronto per la produzione di implementazione di Nova Sonic con AWS CDK, consultate il CDK Sample on. Speech-to-Speech](#) [GitHub](#) Questo esempio illustra:



- Configurazione completa dell'infrastruttura CDK con TypeScript
- WebSocket implementazione del server per comunicazioni in tempo reale
- Implementazione di container con ECS e Fargate

- Configurazione Application Load Balancer per il supporto WebSocket
- Configurazione del gruppo di sicurezza e di rete VPC
- CloudWatch monitoraggio e registrazione
- Le migliori pratiche per le implementazioni di produzione


Sistemi multiagenti

L'architettura multiagente è un modello ampiamente utilizzato per la progettazione di assistenti AI che gestiscono attività complesse. In un assistente vocale basato su Nova 2 Sonic, questa architettura coordina più agenti specializzati, in cui ogni agente opera in modo indipendente per consentire l'elaborazione parallela, il design modulare e soluzioni scalabili.

Nova Sonic funge da orchestratore in un sistema multiagente, svolgendo due funzioni chiave:

Gestione del flusso di conversazione: assicura che tutte le informazioni necessarie vengano raccolte prima di procedere alla fase successiva della conversazione.

Classificazione degli intenti: analizza le richieste degli utenti e le indirizza al subagente specializzato appropriato.



Il diagramma precedente mostra un assistente vocale bancario che utilizza un'architettura multiagente. Il flusso di conversazione inizia con un saluto e la raccolta del nome dell'utente, quindi gestisce le richieste relative al settore bancario o ai mutui tramite subagenti specializzati.

Esempio di flusso di conversazione:

1. L'utente si connette all'assistente vocale.
2. Nova 2 Sonic: «Ciao! Qual è il tuo nome?»
3. Utente: «Mi chiamo John»
4. Nova 2 Sonic: «Ciao John, come posso aiutarti oggi?»
5. Utente: «Voglio controllare il saldo del mio conto»
6. Nova 2 Sonic: [Percorsi verso l'agente di autenticazione]
7. Agente di autenticazione: «Fornisci l'ID del tuo account»
8. Utente: «12345»
9. Agente di autenticazione: [Verifica l'identità]

10Nova 2 Sonic: [Percorsi verso l'agente bancario]

11Agente bancario: «Il tuo saldo attuale è di 5.431,10"»

Sebbene questo esempio dimostri che i subagenti utilizzano il framework Strands Agents distribuito su Amazon AgentCore Bedrock, l'architettura è flessibile. È possibile scegliere:

- Il tuo framework di agenti preferito
- Qualsiasi provider LLM
- Opzioni di hosting personalizzate
- Diversi modelli di orchestrazione

Vantaggi:

- Modularità: ogni agente si concentra su un dominio specifico, semplificando la manutenzione e l'aggiornamento del sistema.
- Scalabilità: aggiungi nuovi agenti senza modificare quelli esistenti, permettendo al sistema di crescere con le tue esigenze.
- Elaborazione parallela: più agenti possono lavorare contemporaneamente, migliorando i tempi di risposta per domande complesse.
- Specializzazione: ogni agente può essere ottimizzato per il suo compito specifico, utilizzando gli strumenti e le basi di conoscenza più appropriati.
- Isolamento dei guasti: se un agente si guasta, gli altri continuano a funzionare, migliorando l'affidabilità complessiva del sistema.

Consulta [questo blog](#) per maggiori dettagli ed esempi di codice.

Consultate il [Nova Sonic Workshop Multi-Agent Lab](#) per esempi pratici.

Integrazione della telefonia

Amazon Nova 2 Sonic si integra con i provider di telefonia per abilitare applicazioni vocali basate sull'intelligenza artificiale accessibili tramite telefonate. Questa guida illustra l'integrazione con Twilio, Vonage e altri sistemi basati su SIP per la creazione di soluzioni di contact center e agenti vocali.

Twilio: piattaforma di comunicazione cloud con funzionalità di streaming vocale e multimediale programmabili.

Vonage: comunicazioni globali APIs con voce, streaming WebSocket audio e connettività SIP.

AWS fornisce un'implementazione di esempio completa che dimostra Nova Sonic in un ambiente di contact center con analisi in tempo reale e integrazione telefonica.

Archivio: [Sample Sonic](#) Contact Center con telefonia

Sistemi avanzati con Amazon Nova

Panoramica di

Questa sezione fornisce una guida completa per gli utenti esperti che implementano modelli avanzati con i modelli Nova. Queste funzionalità consentono applicazioni sofisticate tra cui integrazione di strumenti, generazione aumentata di recupero (RAG) e agenti AI autonomi.

Pensiero esteso in Amazon Nova 2

Amazon Nova 2 Lite introduce funzionalità di pensiero esteso che consentono al modello di impegnarsi in un ragionamento più approfondito per problemi complessi. Questa funzionalità opzionale consente di controllare quando e come il modello alloca risorse di calcolo aggiuntive per affrontare attività impegnative.

Come funziona il pensiero esteso

Amazon Nova 2 introduce il pensiero esteso come funzionalità ibrida. Hai il controllo completo:

- Extended thinking OFF (impostazione predefinita): Amazon Nova 2 funziona con un ragionamento latente efficiente, ottimale per le attività quotidiane e le applicazioni ad alto volume.
- Extended Thinking ON: Amazon Nova 2 utilizza un step-by-step ragionamento esplicito e ottimale per problemi complessi che richiedono un'analisi approfondita.

Sforzo di ragionamento

Quanto segue mostra diversi livelli di sforzo di ragionamento.

Basso sforzo (maxReasoningEffort: "basso»)

Ideale per: attività con maggiore complessità che richiedono un pensiero strutturato. Ad esempio, è possibile utilizzarlo per suggerimenti di revisione e miglioramento del codice laddove il modello debba considerare attentamente la qualità del codice esistente, attività di analisi che richiedono un'attenta considerazione di più fattori o scenari di risoluzione dei problemi che traggono vantaggio da un approccio metodico. Lo sforzo ridotto è ideale per attività complesse in cui il ragionamento di base migliora la precisione senza richiedere una pianificazione approfondita in più fasi.

Sforzo medio (maxReasoningEffort: «medio»)

Ideale per: attività in più fasi e flussi di lavoro di codifica. Ad esempio, è possibile utilizzarlo per lo sviluppo e il debug di software in cui il modello deve comprendere la struttura del codice esistente prima di implementare le modifiche, la generazione di codice che richiede il coordinamento tra più file o componenti, calcoli in più fasi con interdipendenze o attività di pianificazione con più vincoli. Lo sforzo medio è ottimale per i flussi di lavoro agentici che coordinano più strumenti e richiedono che il modello mantenga il contesto in diverse operazioni sequenziali.

Sforzo elevato (maxReasoningEffort: "high»)

Ideale per: ragionamento STEM e risoluzione avanzata dei problemi. Ad esempio, è possibile utilizzarlo per problemi e dimostrazioni matematiche avanzati che richiedono step-by-step verifiche rigorose, analisi scientifiche e attività di ricerca che richiedono indagini approfondite, progettazione di sistemi complessi con considerazioni architettoniche su più dimensioni o scenari decisionali critici con implicazioni significative. Un impegno elevato garantisce la massima precisione per le attività che richiedono un ragionamento sofisticato, un'attenta valutazione delle alternative e una convalida approfondita delle conclusioni.

Avvio rapido: abilitare il pensiero esteso

Il pensiero esteso è controllato tramite il `reasoningConfig` parametro.

```
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"])

```

Parametri di ragionamento:

- `type`: `enabled` o `disabled` (impostazione predefinita: `disabled`)
- `maxReasoningEffort`: `low`, `medium`, o `high`

Note

Temperature, TopP e TopK non possono essere utilizzati con `maxReasoningEffort` set to `high`. L'utilizzo combinato di questi parametri causa un errore.

Per esempi completi di codice che utilizza il pensiero esteso, vedi [the section called “Libreria di codici”](#).

Struttura della risposta

Quando abiliti il pensiero esteso, le risposte includono `reasoningContent` blocchi seguiti da blocchi di `text` contenuto:

```

{
  "output": {

```

```

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

```

Note

Con Amazon Nova 2, i contenuti di ragionamento vengono visualizzati come [REDACTED]. I token di ragionamento ti verranno comunque addebitati perché contribuiscono a migliorare la qualità dell'output. Includiamo ora questo campo nella struttura delle risposte per preservare la possibilità di esporre il contenuto del ragionamento in futuro. Stiamo lavorando attivamente con i clienti per determinare l'approccio migliore per far emergere il processo di ragionamento del modello. Il contenuto del ragionamento viene visualizzato come. [REDACTED] I token di ragionamento ti verranno comunque addebitati, in quanto contribuiscono a migliorare la qualità della risposta.

Opzioni di configurazione

Amazon Nova 2 introduce un nuovo `reasoningConfig` parametro che puoi aggiungere alla struttura di richieste inverse esistente per consentire il ragionamento:

```

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

```

```
}  
}
```

Parametri:

- tipo: Passa da e (l'impostazione predefinita è) "enabled" "disabled" "disabled"
- **maxReasoningEffort**: se abilitato, controlla la profondità del ragionamento
- «low»: attività moderatamente complesse
- «medio»: problemi complessi che richiedono un'analisi approfondita
- «alto»: il ragionamento più completo per compiti molto complessi

Note

durante l'utilizzo "high", temp, TopP e maxToken devono essere disattivati. In questa modalità, il modello esegue un'analisi più approfondita per trovare la soluzione migliore. Questa elaborazione più approfondita può generare un output superiore a 65.000 token. L'importo esatto dipende dalla complessità della richiesta, ma per alcuni problemi abbiamo visto che può arrivare fino a 128K token. Ciò garantisce un ragionamento completo e di alta qualità anziché risultati troncati.

Modelli supportati

Extended thinking è attualmente disponibile in: Amazon Nova 2 Lite (us.amazon.nova-2-lite-v 1:0)

Pensiero esteso con uso di strumenti

Extended Thinking si integra perfettamente con la chiamata agli strumenti, permettendo ad Amazon Nova di ragionare su quali strumenti utilizzare e su come interpretarne i risultati.

Comprensione dei token di ragionamento e dei prezzi

Tipi di token

I token Extended Thinking vengono fatturati come token di output:

- Token di input: il contenuto originale della richiesta (prezzo di input standard)

- Token di output: sono inclusi i token di ragionamento e il contenuto finale della risposta visibile (prezzi di output standard)

Ripartizione dell'utilizzo

Tutti e tre i tipi di token sono inclusi nelle metriche di utilizzo e nella fatturazione. I token di ragionamento hanno lo stesso prezzo dei token di output e appariranno come «REDATTI» nella risposta del modello».

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

Domande frequenti

Perché Amazon Nova 2 Lite mostra «[REDACTED]» per i contenuti di ragionamento anziché mostrare il processo di pensiero del modello?

Il nostro obiettivo principale per questo lancio è garantire che Nova 2 offra la migliore intelligenza per le tue attività, e vedrai che ciò si riflette nella maggiore precisione.

Riconosciamo che la visibilità del processo di ragionamento è preziosa e abbiamo riscontrato un forte interesse da parte dei clienti a comprendere come il modello affronta i problemi.

Stiamo cercando modi per renderlo disponibile a breve.

I Reasoning Token ti verranno comunque fatturati, in quanto rappresentano un lavoro effettivo che migliora la qualità del tuo output

che verranno acquisiti outputTokens insieme ai token di risposta.

Come faccio a sapere se il pensiero esteso funziona se il ragionamento viene oscurato?

Puoi confermare che il pensiero esteso funziona controllando l'output dei reasoningContent blocchi nella risposta (questi appaiono solo quando il ragionamento è abilitato)

Utilizzo degli strumenti (chiamata di funzioni)

Gli strumenti estendono le funzionalità di Amazon Nova collegando il modello a funzionalità esterne come APIs database e ambienti di esecuzione del codice. L'uso degli strumenti consente ad Amazon Nova di accedere a informazioni in tempo reale, eseguire calcoli e interagire con sistemi esterni.

Comprendere il flusso di lavoro relativo all'utilizzo degli strumenti

L'uso dello strumento con Amazon Nova prevede tre fasi chiave:

Interrogazione utente e definizione dello strumento

Definisci gli strumenti fornendo schemi JSON che descrivono le funzionalità e i requisiti di input di ogni strumento. La configurazione dello strumento deve includere dettagli espliciti su quando e come utilizzare ogni strumento.

Selezione dello strumento

Quando un utente invia un messaggio, Amazon Nova lo analizza per determinare se è necessario uno strumento. Questa scelta automatica dello strumento esamina il contesto e decide quale strumento (se presente) richiamare. Se Amazon Nova identifica uno strumento adatto, restituisce il nome dello strumento e i parametri richiesti.

Sei responsabile dell'esecuzione dello strumento in base alla richiesta del modello. Ciò significa scrivere codice che richiami la funzionalità dello strumento ed elabori i parametri di input forniti dal modello.

Restituisci risultati

Dopo aver eseguito lo strumento, invia i risultati ad Amazon Nova in un formato strutturato utilizzando JSON o una combinazione di testo e immagini. Amazon Nova incorpora l'output dello strumento nella risposta finale. Se si verificano errori durante l'esecuzione, indicalo nella risposta dello strumento per consentire ad Amazon Nova di adeguarsi di conseguenza.

Crea uno strumento

Definite gli utensili utilizzando una configurazione dell'utensile che include una serie di strumenti e, facoltativamente, un parametro di scelta dell'utensile. Le specifiche di ogni utensile devono includere:

- Nome: identificatore chiaro per l'utensile

- Descrizione: spiegazione concisa della funzionalità dello strumento
- Schema di input: schema JSON che definisce i parametri obbligatori e opzionali

Example Esempio di configurazione dello strumento

```
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"]  
                    }  
                }  
            }  
        }  
    ]  
}
```

Migliori pratiche per le definizioni degli strumenti

- Assicurati che il nome e la descrizione indichino esplicitamente l'esatta funzionalità dello strumento; evita strumenti che sono eccessivamente simili dal punto di vista semantico
- Includi i principali elementi di differenziazione nella descrizione per aiutare il modello a distinguere tra strumenti simili
- Limita gli schemi JSON a due livelli di nidificazione per ottenere prestazioni ottimali
- Limita gli input utilizzando tipi di schema (ad esempio enum, int, float) anziché descrivere la struttura in testo semplice
- Indica i parametri obbligatori rispetto a quelli opzionali utilizzando la notazione dello schema JSON (ad esempio, «required»: ["param1", «param2"])

- Convalida lo schema JSON utilizzando un validatore standard prima di inviarlo
- Inserisci gli argomenti di stringa lunghi per ultimi nello schema ed evita di annidarli

Output strutturato con decodifica vincolata

I modelli Amazon Nova sfruttano la decodifica vincolata per garantire un'elevata affidabilità negli output generati. Questa tecnica utilizza la grammatica per limitare i possibili token in ogni fase della generazione, evitando chiavi non valide e applicando i tipi di dati corretti in base allo schema definito.

Example Esempio di output strutturato

```
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"}
}
}

```

Opzioni di scelta degli utensili

Amazon Nova supporta tre parametri di scelta degli strumenti:

Strumento

Lo strumento specificato verrà chiamato una sola volta, ideale per casi d'uso di output strutturato

Qualsiasi

Uno degli strumenti forniti verrà chiamato almeno una volta, utile per gli scenari di selezione delle API

Automatico

Il modello decide se chiamare uno strumento e quanti strumenti chiamare (comportamento predefinito)

Chiamate uno strumento

Quando Amazon Nova decide di chiamare uno strumento, restituisce un blocco di utilizzo dello strumento come parte del messaggio dell'assistente con `stopReason` impostato su `«tool_use»`. Il blocco di strumenti contiene il nome dello strumento e i relativi input.

 Note

Esegui le seguenti sezioni di codice in sequenza (Chiamata di uno strumento → Richiamata dello strumento di elaborazione → Restituzione dei risultati dello strumento) in una singola sessione di Python. Per eseguire nuovamente gli esempi, riavviate la sessione di Python.

Example Chiamare uno strumento

```
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']}")

```

Elaborazione delle chiamate agli strumenti

Estrai il nome e gli argomenti dello strumento dal messaggio, quindi richiama lo strumento:

```

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"])

```

Restituzione dei risultati dello strumento

Restituisci i risultati dello strumento utilizzando lo ToolResultBlock schema:

```
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}")
```

Gestione degli errori

Segnala gli errori ad Amazon Nova per consentire la modifica della richiesta e riprova:

```
tool_result_message = {
    "role": "user",
    "content": [
        {
            "toolResult": {
```

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

Considerazioni relative alla sicurezza

- Verifica l'esistenza degli strumenti prima di richiamarli
- Assicurati che gli input siano formattati correttamente
- Verificate che siano disponibili le autorizzazioni appropriate prima dell'esecuzione dello strumento
- Affidati ai dettagli della sessione anziché consentire ad Amazon Nova di inserire le informazioni degli utenti nelle chiamate agli strumenti
- Ricorda che LLMs può provocare allucinazioni nelle chiamate agli strumenti; convalida sempre prima dell'esecuzione

Strumenti di sistema integrati

I modelli Amazon Nova 2.0 includono strumenti integrati completamente gestiti che non richiedono implementazioni personalizzate. Abilita questi strumenti con un semplice interruttore nell'API Converse.

Interprete di codice

Code Interpreter consente a Nova di eseguire in modo sicuro il codice Python in ambienti sandbox isolati. Questo strumento è progettato per calcoli matematici, operazioni logiche e algoritmi iterativi.

Note

Code Interpreter è disponibile nelle regioni IAD, PDX e NRT. AWS Per garantire che le richieste vengano indirizzate a una regione supportata, utilizzate Global CRIS. Quando utilizzi le chiavi API Bedrock, dovrai aggiungere manualmente le InvokeTool autorizzazioni alle definizioni delle politiche. Il ruolo Bedrock predefinito non consente l'azione. InvokeTool

Abilita Code Interpreter specificando il parametro SystemTool:

```
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"])
```

L'interprete esegue il codice in una sandbox e restituisce i risultati in uno schema standard:

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

Web grounding

Il Web grounding consente ad Amazon Nova di accedere a informazioni in tempo reale da Internet, fornendo up-to-date risposte e riducendo le allucinazioni. Abilita specificando lo strumento di sistema `nova_grounding`:

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

Per informazioni dettagliate su Web Grounding, vedere: [the section called “Web grounding”](#)

Model Context Protocol (MCP)

Il Model Context Protocol (MCP) è uno standard aperto che consente connessioni sicure e bidirezionali tra fonti di dati e strumenti basati sull'intelligenza artificiale. Invece di scrivere adattatori personalizzati per ogni API o servizio, esegui un server MCP e consenti ad Amazon Nova di scoprire automaticamente i suoi strumenti tramite un bridge client.

Una volta connesso, Amazon Nova tratta gli strumenti MCP come qualsiasi altra integrazione esterna: decide quando chiamarli, invia i parametri richiesti e incorpora i risultati nelle risposte. L'uso di Amazon Nova con Strands semplifica questa operazione grazie a un sistema integrato MCPClient che gestisce automaticamente il rilevamento, la connessione e la mappatura dei risultati.

Creazione di agenti IA

I modelli Amazon Nova sono ottimizzati per la creazione di agenti di intelligenza artificiale con Amazon Nova Act. I modelli offrono un migliore utilizzo degli strumenti, un migliore ragionamento per le attività in più fasi, una maggiore capacità di mantenere il contesto tra flussi di lavoro complessi con agenti e il supporto per strumenti MCP remoti.

Creazione di un agente

Gli agenti di intelligenza artificiale creati con Nova possono orchestrare più chiamate agli strumenti, mantenere il contesto durante le interazioni estese e correggere la rotta quando necessario. Il pensiero esteso trasforma i flussi di lavoro agentici abilitando un ragionamento sistematico attraverso obiettivi complessi. Prendi in considerazione l'utilizzo di un framework di pianificazione SDK come Strands Agents per rendere più robusto il processo di pianificazione ed esecuzione dei tuoi sistemi di agenti.

Modelli di progettazione degli agenti

Quando si progettano agenti con Nova:

- Abilita il ragionamento a medio o alto per ottenere i migliori risultati per flussi di lavoro complessi in più fasi che richiedono pianificazione e verifica
- autoImplementa la scelta degli strumenti per consentire una selezione flessibile degli strumenti tra le interazioni tra gli agenti
- Gestione degli errori di progettazione che consenta agli agenti di ripristinare e riprovare con approcci modificati
- Conserva la cronologia delle conversazioni per preservare il contesto tra le interazioni con gli agenti
- Implementa solidi meccanismi di filtraggio e moderazione dei contenuti sui contenuti non controllati utilizzati dal tuo sistema di agenti. Ad esempio, Amazon offre Amazon Bedrock Guardrails, una funzionalità progettata per applicare misure di protezione a più modelli di base, knowledge base e agenti. Questi guardrail possono filtrare i contenuti dannosi, bloccare gli argomenti negati e oscurare informazioni sensibili come le informazioni di identificazione personale.

Esempio di agente multiutensile

```
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"
    #}
#}
)
```

Invocazione di un agente

La chiamata all'agente implica la gestione del flusso di conversazione, l'elaborazione delle chiamate agli strumenti e il mantenimento dello stato durante più interazioni.

Streaming delle risposte degli agenti

Trasmetti le risposte per fornire visibilità in tempo reale sul ragionamento e sulle azioni dell'agente:

```
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)

```

Gestione dello stato dell'agente

Conserva la cronologia delle conversazioni e i risultati degli strumenti per preservare il contesto; l'esempio seguente lo dimostra per un singolo turno, ma lo sviluppatore può determinare come orchestrare il sistema generale degli agenti in base ai requisiti del flusso di lavoro. Inoltre, gli strumenti di Amazon Web Services come Strands gestiscono il contesto dell'agente e lo stato dello strumento per conto dello sviluppatore.

```

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
    #)

```

Best practice per gli agenti

Per ulteriori informazioni sulle best practice degli agenti, vedere [the section called “Best practice”](#).

Per indicazioni sullo sviluppo di agenti di intelligenza artificiale conversazionale, consulta. [Da voce a voce](#)

Web grounding

Web Grounding consente ad Amazon Nova di cercare sul Web informazioni aggiornate e fornire risposte con citazioni. Questa funzionalità è utile per le query che richiedono up-to-date informazioni oltre ai dati di addestramento del modello.

Come funziona il web grounding

Quando il web grounding è abilitato per un prompt, vengono portati a termine i seguenti passaggi:

1. Richiedi configurazione: l'applicazione invia un prompt utente all'API Amazon Bedrock con `nova_grounding` abilitato come `systemTool`
2. Ricerca e analisi: il modello determina se è necessaria la ricerca, esegue una o più ricerche per trovare informazioni pertinenti e valuta se sono necessarie ricerche aggiuntive per ampliarne la comprensione o approfondire argomenti secondari specifici.
3. Generazione di risposte: Amazon Nova sintetizza automaticamente le informazioni dai risultati di ricerca per generare una risposta API finale basata su informazioni in tempo reale, completa di citazioni alle sue fonti.

Come usare il web grounding

Per esempi completi di codice che utilizza Web Grounding, consulta la sezione Esempi di codice.

Per includere Web Grounding nei risultati, specificate il seguente `systemTool` parametro nel blocco `ToolConfig`:

```
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)

```

Disponibilità regionale

Web Grounding è attualmente disponibile solo nelle regioni degli Stati Uniti e supportato solo dai profili CRIS statunitensi.

Struttura della risposta

Di seguito è riportata una risposta di esempio. La risposta è stata abbreviata per motivi di brevità:

```

{
  "output": {
    "message": {

```



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

Ogni citazione include:

- **text**: Un segmento della risposta generata dal modello.
- **citationsContent**: Il contenitore principale per i dati di citazione relativi a un segmento di testo.
- **citations**: Un contenitore all'interno **citationsContent** che contiene la posizione di una citazione.
- **location**: Un contenitore all'interno **citations** che contiene la fonte di una citazione.
- **web**: Un contenitore all'interno **location** che contiene i dettagli della fonte web.
- **url**: L'indirizzo web completo (URL) della fonte della citazione.
- **domain**: Il dominio principale dell'URL di origine.

Sicurezza di messa a terra

I tuoi dati non lasciano mai l' AWS infrastruttura. Le query generate dai modelli rimangono all'interno AWS dei servizi e non vengono mai inviate a Internet in senso lato. Il nostro ampio indice di ricerca web interno e i nostri grafici di conoscenza danno priorità a fonti affidabili e di alta qualità e filtrano i contenuti dannosi in caso di ingresso. Infine, proteggiamo la tua applicazione dall'iniezione indiretta di prompt e dalla diffusione di informazioni errate tramite il filtraggio runtime (si noti che questa mitigazione è limitata per le lingue diverse dall'inglese).

Gestione degli errori

Non includere una voce `toolSpec` con il nome `nova_grounding`. L'inclusione di uno strumento con questo nome causerà un errore.

Di seguito è riportato un elenco di potenziali errori che possono verificarsi durante l'utilizzo del web grounding:

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

Autorizzazioni necessarie per gli strumenti integrati

Per garantire che il tuo ruolo possa accedere a Web Grounding su Amazon Bedrock, hai due opzioni:

1. Attiva `BedrockFullAccess` il tuo ruolo IAM: in caso affermativo `BedrockFullAccess`, avrà accesso automatico a Web Grounding.
2. Aggiungi autorizzazioni specifiche (se necessario): se hai bisogno di un controllo degli accessi più granulare, aggiungi questa politica alla politica IAM del tuo ruolo, sostituendo l'ID dell'account con il tuo ID: Account AWS

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

Web Grounding ha la chiave di `aws:requestedRegion` condizione impostata su «non specificato». Se le politiche esistenti o le politiche di controllo del servizio (SCPs) applicano questa condizione, è possibile che si verifichino problemi di accesso. L'aggiornamento della condizione per consentire una `requestedRegion` «non specificata» può risolvere questo problema.

 Note

Se abiliti lo strumento di web grounding, sei responsabile dell'uso che ne fai e di qualsiasi uso da parte dei tuoi utenti finali dei risultati che incorporano informazioni basate sul web grounding. Saprai quando il tuo output include informazioni basate sul web grounding da citazioni o collegamenti al materiale originale. Devi conservare e visualizzare queste citazioni e questi collegamenti nell'output fornito agli utenti finali.

 Note

Il web grounding è un costo aggiuntivo. Per ulteriori informazioni, consulta la pagina dei prezzi di [AWS Bedrock](#).

Guida ingegneristica tempestiva

La progettazione tempestiva è la pratica di progettazione di istruzioni per comunicare efficacemente con modelli linguistici di grandi dimensioni (LLMs) come Amazon Nova. La progettazione tempestiva consente di controllare il comportamento del modello, migliorare la qualità dell'output e creare applicazioni affidabili basate sull'intelligenza artificiale.

Un'efficace progettazione tempestiva implica la creazione di input che guidino i modelli a produrre gli output desiderati. Un prompt ben strutturato fornisce istruzioni chiare, contesto pertinente e dati di input formattati correttamente.

Cos'è l'ingegneria tempestiva

La progettazione dei prompt si riferisce alla pratica di ottimizzare l'input testuale in un modello linguistico di grandi dimensioni (LLM) per migliorare l'output e ricevere le risposte desiderate. I prompt consentono a un LLM di svolgere un'ampia varietà di attività tra cui classificazione, risposta a domande, generazione di codice, scrittura creativa e altro ancora. La qualità dei prompt forniti a un LLM può influire sulla qualità delle risposte del modello. Questa sezione fornisce le informazioni necessarie per iniziare a utilizzare la progettazione dei prompt. Include anche strumenti per aiutarti a trovare il miglior formato di prompt possibile per il tuo caso d'uso quando utilizzi un LLM su Amazon Bedrock.

L'efficacia dei prompt dipende dalla qualità delle informazioni fornite e dalla realizzazione del prompt stesso. I prompt possono comprendere istruzioni, domande, dettagli contestuali, input ed esempi per guidare efficacemente il modello e migliorare la qualità dei risultati. Questo documento descrive strategie e tattiche per ottimizzare le prestazioni della famiglia di modelli Amazon Nova 2 Sonic. I metodi qui presentati possono essere utilizzati in varie combinazioni per aumentarne l'efficacia. Ti invitiamo a impegnarti nella sperimentazione per identificare gli approcci più adatti alle loro esigenze specifiche.

Iniziare con la progettazione tempestiva

Prima di iniziare la progettazione dei prompt, ti consigliamo di disporre dei seguenti elementi, in modo da poter sviluppare in modo iterativo il prompt più ottimale per il tuo caso d'uso:

Definisci il tuo caso d'uso

Definisci il tuo caso d'uso in quattro dimensioni:

- **Compito:** definisci ciò che desideri che il modello realizzi. Ciò determina la giusta tecnica di suggerimento.
- **Ruolo:** definisci il ruolo che il modello deve assumere per svolgere l'attività. I modelli Amazon Nova supportano tre ruoli (Sistema, Utente o Assistente).
- **Stile di risposta:** definisci la struttura o lo stile di risposta che il modello deve seguire in base al pubblico, ad esempio JSON, markdown o conversazionale.
- **Istruzioni:** definisci l'insieme di istruzioni che il modello deve seguire per soddisfare i criteri di successo.

Stabilisci criteri di successo

Definisci criteri di successo o metriche di valutazione. Puoi fornire un elenco di criteri o fornire metriche di valutazione specifiche, come lunghezza, punteggio BLEU, ROUGE, formato, fattualità e fedeltà.

Elaborare un prompt

Crea un prompt iniziale che includa attività, ruolo, stile di risposta e istruzioni. Iterate in base ai risultati.

L'efficacia dei prompt dipende dalla qualità delle informazioni fornite.

Best practice generali

Le seguenti best practice si applicano principalmente ai modelli di testo di Amazon Nova, ma puoi applicarle ad altri modelli, oltre alle best practice specifiche per modalità.

Per ulteriori informazioni su come richiedere input multimodali, consulta [Richiesta di ingressi multimodali](#). Per informazioni su come richiedere input vocali, fare riferimento a [Istruzioni per le conversazioni vocali](#).

Comprensione dei ruoli

I modelli Amazon Nova consentono di strutturare i prompt utilizzando tre ruoli distinti: sistema, utente e assistente.

- **Sistema (opzionale):** sebbene non sia obbligatorio, stabilisce i parametri comportamentali generali dell'assistente. Può anche essere utilizzato per fornire istruzioni e linee guida aggiuntive che l'utente desidera che il modello rispetti per tutta la conversazione.

- Utente: può facoltativamente comunicare il contesto, le attività, le istruzioni e il risultato desiderato insieme alla richiesta dell'utente.
- Assistente: aiuta a guidare il modello verso la risposta prevista.

Argomenti

- [Crea istruzioni precise](#)
- [Concentrare l'attenzione su sezioni del prompt](#)
- [Utilizzo del ruolo di sistema](#)
- [Fornire esempi \(few-shot prompting\)](#)
- [Sistemi di chiamata degli strumenti](#)
- [Tecniche di suggerimento avanzate](#)

Crea istruzioni precise

La creazione di query specifiche degli utenti è fondamentale per la progettazione dei prompt. Le query ben elaborate indirizzano i modelli per la comprensione del testo di Amazon Nova al fine di generare risposte accurate e pertinenti. Per creare tali query, è essenziale iniziare fornendo informazioni contestuali al loro interno. Il contesto fornito aiuta a collocare meglio il modello allineandolo a scenari chiari rivolti all'utente target, migliorando così la pertinenza e la coerenza del risultato.

Fornire informazioni contestuali e specifiche

I modelli funzionano meglio se le istruzioni sono chiare, ben strutturate, brevi e specifiche. Questa guida ai modelli di prompt si applica sia al prompt dell'utente che al prompt di sistema.

Modello Prompt

```
# 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}"""

```

Esempio: informazioni specifiche e contestuali

Di seguito è illustrato un esempio di prompt che viene riscritto con informazioni specifiche e contestuali. L'aggiunta di maggiori informazioni contestuali aiuta il modello a orientarsi verso il comportamento desiderato.

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]

- **Esprimiti con chiarezza:** quando crei il modello, cerca di mantenere le istruzioni il più chiare possibile in modo da assicurare la loro comprensione da parte di un umano, anziché da una macchina (ad esempio, un elenco in stile JSON).
- **Entra nello specifico:** fornisci al modello istruzioni specifiche sull'attività, sull'output previsto e su qualsiasi contesto aggiuntivo per aiutare il modello a rispondere nel modo desiderato.

Specifica il formato e lo stile dell'output

Se desideri che Amazon Nova 2 generi risposte personalizzate in base alle tue esigenze specifiche, puoi specificare il formato e lo stile dell'output. Ad esempio, se desideri generare risposte solo in JSON o limitare la lunghezza della risposta a un numero massimo di parole, elenchi o paragrafi. Ciò consente ad Amazon Nova 2 di comprendere meglio le tue esigenze e produrre output più pertinenti e facili da analizzare.

Utilizza lettere maiuscole e formulazioni forti come NON+VERBO o DEVI per enfatizzare le regole che il modello deve rispettare rigorosamente. Ad esempio, se desideri un solo oggetto JSON nella risposta, puoi istruire il modello dicendo "DEVI rispondere solo in formato JSON. NON utilizzare nessun altro formato per rispondere alla domanda".

Di seguito sono illustrati degli esempi di prompt riscritti con informazioni specifiche e contestuali. L'aggiunta di maggiori informazioni contestuali aiuta il modello a orientarsi verso il comportamento desiderato.

Esempio 1: fornisci dettagli extra

L'aggiunta di ulteriori dettagli sulla formattazione della risposta può aiutare il modello a ottenere il risultato desiderato. Altri formati di risposta comunemente usati sono CSV, Markdown, YAML e 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
` ``

```

## Esempio 2: imposta vincoli di stile

In questo caso, il prompt con vincoli di stile fornisce informazioni complete sui vincoli da seguire e sul formato di risposta desiderato. Come osservato nella risposta, il prompt ottimizzato si allinea maggiormente alla brevità richiesta e alla struttura dell'elenco puntato.

### 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.

### Esempio 3: limita il formato di risposta

Qui, il prompt con il formato di risposta forza il modello a rispondere solo con il numero di categoria e a limitarlo a un valore compreso tra 1 e 10, invece di essere molto dettagliato.

### 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

## Fornisci prompt chiari e rapidi

Oltre al contesto iniziale, un formato di query strutturato svolge un ruolo significativo nell'ottimizzazione delle interazioni con il modello linguistico. La separazione di parti distinte dell'input con delimitatori garantisce chiarezza e migliora la capacità dei modelli Amazon Nova 2 di comprendere la struttura della query. Un altro modo efficace consiste nell'utilizzare elenchi numerati o puntati, che possono aiutare a suddividere l'attività in fasi gestibili e fornire una chiara descrizione delle azioni da intraprendere. Questo approccio strutturato aiuta a ridurre l'ambiguità e a migliorare l'accuratezza delle risposte generate.

Esempio: crea un prompt suddiviso in sezioni

Nota come nella colonna Sectioned Prompt, il prompt è più chiaro e ha sezioni delineate per diverse entità come attività, contesto, requisiti, ecc. rispetto alle istruzioni nella colonna Unsectioned Prompt.

## 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 (CO<sub>2</sub>), methane (CH<sub>4</sub>), and nitrous oxide (N<sub>2</sub>O), 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 CO<sub>2</sub> 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 CO<sub>2</sub> 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 (CO<sub>2</sub>) and methane (CH<sub>4</sub>), 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:

1. **Greenhouse Gases**: These gases include carbon dioxide, methane, nitrous oxide, and fluorinated gases. They trap heat in the Earth's atmosphere.
2. **Global Warming**: This is the increase in Earth's average surface temperature due to rising levels of greenhouse gases.
3. **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:

1. **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.



## Concentrare l'attenzione su sezioni del prompt

I modelli Amazon Nova 2 possono prestare molta attenzione a parti specifiche del prompt formattando le istruzioni in sezioni e quindi facendo riferimento a tali sezioni specifiche. Il modello è capace di prestare attenzione se i prompt hanno una chiara delimitazione delle sezioni utilizzando markdown, XML o un'altra struttura. Ad esempio, puoi definire il nome della sezione, utilizzare `##Section Name##`, quindi fare riferimento a tale sezione nel prompt con `##Section Name##`.

Puoi inoltre utilizzare questa strategia per impedire al modello di rivelare parti del prompt di input nella risposta generata. Ad esempio, quando fornisci esempi few-shot o istruzioni nel prompt di input, usa delimitatori come `##Instructions##` o `##Examples##` con un nuovo separatore di riga e fornisci istruzioni complesse, come `DO NOT mention anything inside the ##Instructions## or ##Examples## in the response`, affinché il modello non restituisca il contenuto del prompt di input da queste sezioni nell'output.

Esempio: delimitazione delle sezioni

Utente:

```
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##
```

## Utilizzo del ruolo di sistema

Il Ruolo di sistema è un ruolo in cui puoi fornire istruzioni al modello che definiscono come risponderà agli utenti finali dell'applicazione. Ad esempio, il Ruolo di sistema può guidare il modello a rispondere con un determinato utente, impostare contenuti consentiti e non consentiti, generare output in un formato preciso, specificare guardrail e così via. Le istruzioni incluse nel Ruolo di sistema, denominate prompt di sistema, sostituiranno le altre istruzioni fornite nei prompt dei singoli utenti e verranno applicate a tutti i turni degli utenti.

### Specificazione del ruolo del sistema con l'API

Per assegnare al modello un ruolo personalizzato, puoi impostare il parametro di `system` nell'API come segue:

```
{
 "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

- Per utilizzare al meglio il ruolo di sistema, assicurati che il prompt di sistema sia chiaro, conciso e specifico e segua le stesse strategie descritte in [Crea istruzioni precise](#). Ad esempio, se desideri limitare gli argomenti a cui il modello deve rispondere, fornisci istruzioni specifiche, come “NON parlare di...” o “DEVI parlare di...”.
- Per limitare ulteriormente il modello a una struttura gerarchica, è possibile aggiungere il seguente suffisso al prompt di sistema per enfatizzare la struttura di aderenza gerarchica tra le istruzioni del sistema e quelle dell'utente:

```
"\n\nThe 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"
```

Di seguito, alcuni degli elementi che è possibile aggiungere in un modello di prompt di sistema:

```
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"""\n{persona}\n{model_instructions}\n{response_schema}\n{guardrails}\n"""
```

Per assegnare al prompt di sistema la struttura gerarchica di aderenza tra le istruzioni del sistema e quelle dell'utente, è possibile aggiungere quanto segue:

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.

#### Esempio 1: Fornire indicazioni linguistiche specifiche

Dopo aver aggiunto il prompt di sistema, le risposte dei modelli sono altamente stilizzate verso lo stile di un antico manoscritto medievale, come indicato nel Prompt di sistema.

#### Without a System Prompt

Sistema:

NA

Utente:

Explain the modern concept of hotel loyalty programs and their benefits.

Assistente:

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

### Sistema:

Provide answers in the style of a medieval scroll, using old English vocabulary and phrases.

### Utente:

Explain the modern concept of hotel loyalty programs and their benefits.

Assistente:

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.

## Esempio 2: fornitura di guardrail

Con l'aggiunta del prompt di sistema, gli utenti possono aggiungere dei guardrail alle proprie applicazioni per proteggerle da qualsiasi uso non intenzionale. Ecco un esempio di come i guardrail possono focalizzare il modello sull'attività desiderata.

### Without a System Prompt

Sistema:

NA

Utente:

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.)

Assistente:

**\*\*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

Sistema:

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

Utente:

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.)

Assistente:

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.

## Fornire esempi (few-shot prompting)

Includendo alcuni esempi della tua attività nel prompt, puoi creare un modello strutturato da seguire per Amazon Nova 2. In questo modo, è possibile ridurre l'ambiguità e migliorare la precisione e la qualità dell'output. La tecnica che consiste nel fornire esempi chiari per rendere le risposte del modello più vicine al risultato desiderato si chiama few-shot prompting.

Il few-shot prompting consiste nel fornire al modello linguistico alcuni esempi (shot) dell'attività, insieme al formato di input e output, e quindi chiedergli di generare l'output per un nuovo input basato sugli esempi forniti. Questo metodo aiuta anche a chiarire istruzioni o attività complesse, facilitando la comprensione e l'interpretazione di ciò che viene richiesto da Amazon Nova 2.

Come può aiutare l'aggiunta di esempi al prompt:

L'aggiunta di esempi può aiutare il modello a produrre:

- risposte coerenti e uniformi allo stile degli esempi;
- risposte efficienti grazie alla diminuzione della probabilità di interpretare erroneamente le istruzioni e alla riduzione al minimo delle allucinazioni.

La portata del miglioramento delle prestazioni del modello tramite il few-shot prompting dipenderà dalla qualità e dalla diversità degli esempi scelti. I seguenti elementi illustrano quali sono le caratteristiche di buoni shot nel prompt:

- **Seleziona diversi esempi:** gli esempi scelti devono rappresentare la distribuzione prevista input/output in termini di diversità (dai casi d'uso comuni ai casi limite) per coprire adeguatamente i casi d'uso pertinenti. È importante evitare qualsiasi bias negli esempi, poiché un bias negli input può causare bias anche negli output.
- **Livelli di complessità corrispondenti:** la complessità degli esempi forniti deve essere in linea con l'attività o lo scenario di destinazione. È importante assicurarsi che il grado di complessità sia mappato tra l'input previsto e l'esempio scelto nel prompt.
- **Pertinenza garantita:** gli esempi selezionati devono essere direttamente pertinenti al problema o all'obiettivo in questione. Ciò garantisce la coerenza e l'uniformità delle risposte.

#### Tip

Se i suggerimenti precedenti non funzionano, consigliamo di creare un sistema basato su generazione potenziata da recupero dati (RAG) che migliori il prompt con una selezione dinamica di shot basata sulle analogie tra la query di input dell'utente e un pool di shot disponibile.

Esempio 1: fornire esempi nel prompt dell'utente

In questo caso, l'utente sta cercando di classificare i ticket di assistenza clienti in entrata in categorie predefinite. Puoi fornire ai modelli di Amazon Nova 2 alcuni esempi di ticket classificati correttamente per migliorare la comprensione delle categorie e della lingua utilizzata nei ticket. Gli esempi devono essere concisi e rappresentare tutte le attività previste dall'applicazione. Se esiste un nome di campo

specifico significato per le attività, come Ticket o Category in questo esempio, l'utente può utilizzare tali campi seguiti direttamente dai due punti ":".

### 0-shot prompt

Utente:

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."

Assistente:

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

Utente:

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."

**Assistente:**

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.

**Esempio 2:** fornire esempi sotto forma di prompt a turni

In questo caso, gli esempi vengono forniti come turni, un turno per esempio, in cui il ruolo User contiene l'input e il ruolo Assistant contiene l'output previsto per tale esempio.

**0-shot Prompt**

**Sistema:**

Your task is to Classify the following texts into the appropriate categories. The categories to classify are:

Categories:

- Food
- Entertainment
- Health
- Wealth
- Other

**Utente:**

I have 20\$ in my pocket.

**Assistente:**

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)

Sistema:

Your task is to Classify the following texts into the appropriate categories. The categories to classify are:

Categories:

- Food
- Entertainment
- Health
- Wealth
- Other

Utente:

I love to eat pizza.

Assistente:

Food

Utente:

I enjoy watching movies.

Assistente:

Entertainment

Utente:

I am going to the gym after this.

Assistente:

Health

Utente:

I have 20\$ in my pocket.

Assistente:

Wealth

### Esempio 3: fornire esempi nel prompt di sistema

In questo caso, puoi specificare una sezione “Esempi” e poi elencare una serie di esempi all’interno del prompt di sistema. Questa modalità di fornire esempi nel prompt è particolarmente utile se gli esempi sono lunghi e complessi e aiuta il modello a individuare gli shot di esempio.

#### 0-shot Prompt

Sistema:

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.

Utente:

Draft a detailed project update report for our stakeholders, summarizing the project milestones achieved, tasks completed, and future plans.

Assistente:

# 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

### Sistema:

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>  
<hr>

<b>Project Milestones Achieved:</b><br>  
- Successfully launched the new CRM system.<br>  
- Integrated the marketing automation tool.<br>  
- Completed the employee training sessions.

<b>Tasks Completed:</b><br>  
- Developed the user manual.<br>  
- Conducted system testing.<br>  
- Prepared the training materials.

<b>Future Plans:</b><br>  
- Roll out the CRM system to all departments.<br>  
- Schedule follow-up training sessions.<br>  
- Monitor system performance and make necessary adjustments.

<hr>  
<b>Prepared by:</b><br>  
[Your Name]<br>  
[Your Position]<br>  
[Your Contact Information]

#### <Example 2>

<b>Project Update Report</b><br>  
<i>Date:</i> February 20, 2023<br>

```

<hr>

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>
Prepared by:

[Your Name]

[Your Position]

[Your Contact Information]

```

### Utente:

Draft a detailed project update report for our stakeholders, summarizing the project milestones achieved, tasks completed, and future plans.

### Assistente:

```

Project Update Report

<i>Date:</i> October 5, 2023

<hr>

Project Milestones Achieved:

- Successfully completed the implementation of the new enterprise resource planning (ERP) system.

- Conducted and completed the first phase of the data migration process.

- Successfully launched the new inventory management module.

Tasks Completed:

- Developed and finalized the comprehensive user training program, including detailed user manuals and video tutorials.


```

- 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.

## Sistemi di chiamata degli strumenti

La chiamata degli strumenti è disponibile per i modelli Amazon Nova inserendo uno schema di configurazione dello strumento nella richiesta. Il prompt per il modello verrà potenziato con questa configurazione dello strumento, quindi è un punto di grande impatto per iniziare a ottimizzare il sistema di chiamata degli strumenti.

Considera questi principi chiave:

- Le definizioni degli strumenti devono essere chiare e concise. Devono essere facili da capire e l'intento deve essere estremamente chiaro.
- Utilizza i principali fattori di differenziazione e le condizioni limite per definire quando utilizzare uno strumento rispetto a un altro.

- Sii critico sui tipi di argomenti di input. Chiediti se hanno senso e se ci si aspetterebbe che vengano usati normalmente in quel modo.

Utilizza “Scelta dello strumento” per controllare quando viene chiamato uno strumento

Il parametro di scelta dello strumento consente di personalizzare il comportamento della chiamata degli strumenti con il modello. Ti consigliamo di utilizzarlo per un controllo preciso su quali strumenti vengono chiamati e quando.

Ad esempio, per casi d’uso come l’output strutturato, potresti voler chiamare uno strumento specifico ogni volta che viene invocato Amazon Nova. Puoi definire lo schema del tuo output come strumento e poi impostare la scelta dello strumento sul nome di quello strumento.

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

Per molti casi d’uso agentici, potresti voler assicurarti che il modello selezioni sempre uno degli strumenti disponibili. A tale scopo, puoi impostare la scelta dello strumento su any, che chiamerà esattamente uno strumento ogni volta che viene invocato il modello.

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

Infine, per i casi d’uso in cui il richiamo di uno strumento dipende in larga misura dal contesto della conversazione, puoi impostare la scelta dello strumento su auto. Questo è il comportamento predefinito e lascerà la selezione dello strumento completamente al modello.

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

```
}
```

## Tecniche di suggerimento avanzate

Queste sezioni forniscono indicazioni avanzate su come migliorare la qualità dei prompt e sfruttare funzionalità chiave come il pensiero esteso.

### Usa la modalità Reasoning

I modelli Amazon Nova 2 offrono una modalità di ragionamento opzionale che migliora l'approccio del modello alla risoluzione di problemi complessi consentendogli di risolvere i problemi in modo sistematico prima di rispondere. Sfruttare la modalità di ragionamento del modello è un modo efficace per migliorare la precisione dei suggerimenti.

Quando utilizzarla: la modalità Reasoning è consigliata per attività complesse come casi d'uso con:

- Diverse fasi di ragionamento: dimostrazioni matematiche, progettazione di algoritmi, architettura del sistema
- Informazioni incrociate: analisi dei documenti, confronto delle opzioni, valutazione dei compromessi
- Calcoli soggetti a errori: modellazione finanziaria, analisi dei dati, debug complessi
- Pianificazione con vincoli: ottimizzazione delle risorse, gestione delle dipendenze, valutazione del rischio
- Classificazioni complesse: categorizzazione multietichetta, tassonomie gerarchiche, limiti decisionali differenziati
- Scenari di utilizzo degli strumenti: flussi di lavoro API in più fasi, ottimizzazione delle interrogazioni dei database, integrazioni di sistemi coordinate

#### Note

Per ulteriori informazioni sulla modalità di ragionamento, fare riferimento a [Usare il ragionamento](#)

### Adotta un approccio dall'alto verso il basso

Nelle situazioni in cui il modello deve valutare diversi approcci per risolvere il problema, suggeritegli di adottare un approccio dall'alto verso il basso.

- I modelli Amazon Nova 2 offrono prestazioni migliori quando il modello parte da un quadro generale e poi lo suddivide in sottoproblemi o passaggi più piccoli e dettagliati.
- Chiedi esplicitamente al modello di identificare innanzitutto l'obiettivo principale, quindi di scomporlo in componenti gestibili prima di elaborare i dettagli di ogni parte.
- Questo approccio strutturato aiuta il modello a organizzare il suo pensiero e a produrre catene di ragionamento più coerenti.

Esempio:

```
{{User query}}. Start with the big picture and break it down into progressively smaller, more detailed subproblems or steps.
```

Dirigi la catena di pensiero

Sebbene la modalità di ragionamento offra una maggiore precisione attraverso la risoluzione sistematica dei problemi, esistono scenari specifici in cui i suggerimenti di Chain of Thought (CoT) in modalità non ragionamento possono soddisfare meglio le vostre esigenze.

Quando utilizzarla:

- Trasparenza e verificabilità: quando si desidera vedere, verificare o controllare il processo di ragionamento del modello, CoT offre una visibilità completa in ogni fase. Questo è fondamentale per i settori regolamentati, per le decisioni ad alto rischio o quando si desidera documentare la logica alla base di una risposta.
- Strutture di ragionamento personalizzate: utilizzate CoT per applicare modelli o metodologie di ragionamento specifici. Potete guidare il modello affinché segua i quadri decisionali della vostra organizzazione, utilizzi approcci di risoluzione dei problemi specifici del dominio o assicuratevi che i fattori siano considerati in un ordine specifico.
- Sviluppo e debug rapidi: durante la fase di progettazione tempestiva, CoT aiuta a capire in che modo il modello affronta i problemi, a identificare i punti in cui il ragionamento si interrompe e a iterare in base alle richieste in modo più efficace.
- Approcci ibridi: prendete in considerazione l'utilizzo di CoT durante lo sviluppo per perfezionare i prompt, quindi passate alla modalità di ragionamento per l'implementazione in produzione una volta che sarete sicuri dell'approccio del modello al vostro caso d'uso specifico.

 Note

Non tutte le attività richiedono CoT. Per attività più semplici, consenti al modello di utilizzare il proprio processo di ragionamento.

Guida alla direzione del CoT del modello:

```
{{User query}} Please follow these steps:
```

1. {{Step 1}}
2. {{Step 2}}
- ...

Utilizzo di finestre contestuali lunghe

I modelli Amazon Nova 2 hanno una lunghezza del contesto supportata di 1 milione di token ed eccellono nella comprensione del codice e nella risposta alle domande su documenti lunghi. Le sue prestazioni (inclusa la tempestiva aderenza del sistema e l'uso degli strumenti) possono diminuire leggermente all'aumentare delle dimensioni del contesto.

Come utilizzarlo:

- Metti i dati in formato lungo all'inizio: posiziona i documenti e gli input lunghi vicino all'inizio del prompt. Inseriscili prima della domanda, delle istruzioni e degli esempi.
- Metti le istruzioni alla fine: posiziona le istruzioni alla fine del prompt. Il modello funziona al meglio quando il contesto viene fornito per primo e le istruzioni vengono fornite alla fine.
- Strutturate gli indicatori di inizio e fine del contenuto del documento: utilizzate i marcatori di inizio e fine, come DOCUMENT {idx} START e DOCUMENT {idx} END, per indicare l'inizio e la fine di documenti lunghi in cui {idx} rappresenta l'indice del documento specifico.

Modello di esempio:

```
// 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
```

## Risposte fondate nel testo di supporto

Ti consigliamo di fornire al modello informazioni attendibili pertinenti alla query di input. Queste informazioni, insieme alla query di input, fanno spesso parte del sistema chiamato retrieval augmented generation (RAG).

- In questo processo, alcuni documenti o informazioni pertinenti e contestuali vengono aggiornati in base alle richieste effettive dell'utente, in modo che il modello ottenga contenuti affidabili per generare una risposta pertinente e accurata.
- Chiedere ad Amazon Nova 2 di rispondere utilizzando un testo di riferimento proveniente da una fonte attendibile può guidarlo a redigere la risposta sulla base del materiale fornito e garantire che la risposta sia basata su informazioni accurate e pertinenti, migliorando l'affidabilità e la credibilità dei contenuti generati.
- L'uso di un testo di riferimento può aiutare a evitare allucinazioni, migliorando così la qualità e l'affidabilità complessive delle risposte. Per ridurre al minimo le allucinazioni, consigliamo di menzionare esplicitamente **DO NOT USE INFORMATION THAT IS NOT IN REFERENCE TEXTS!** nelle istruzioni del modello.

## Modello Prompt

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}
```

Esempio: fornire un contesto di base aiuta a prevenire allucinazioni al modello

Questo esempio mostra come il contesto di base può impedire al modello di avere allucinazioni.

Sistema:

```
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!
```

Utente:

```
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.
```

Terra usando marcatori di citazione

Per le attività relative a documenti lunghi, consigliamo di indicare al modello Amazon Nova 2 di basare le proprie risposte utilizzando citazioni dalle sezioni pertinenti dei documenti prima di procedere con l'attività.

Questo approccio aiuta il modello a concentrarsi sulle informazioni più pertinenti ed evitare di farsi distrarre da contenuti estranei. Quando richiedi che il modello basi la sua risposta, le sezioni che possono essere citate devono essere numerate. Ad esempio `Passage %[1]%`, `Passage %[2]%` e così via.

## Esempi: utilizzo di marcatori di citazione

### Example Richiesta dei marcatori di citazione

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)
...
```

Dopo aver estratto le informazioni chiave in base all'attività dell'utente, puoi utilizzare le metriche finanziarie estratte per rispondere alle domande pertinenti, come mostrato:

### Example Analisi di follow-up con metriche estratte

## 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

## Usa Nova Web Grounding

Invece di richiedere direttamente le citazioni per fondare il modello nel testo di supporto, i modelli Amazon Nova 2 forniscono uno strumento di web grounding interno che può essere utilizzato. Se abilitati, i modelli di Amazon Nova 2 interrogheranno direttamente il Web e i grafici della conoscenza di Amazon e baseranno la risposta finale con citazioni.

Per ulteriori informazioni su come sfruttare Amazon Nova Web Grounding, puoi fare riferimento alla guida per l'utente di [Amazon Nova Web Grounding](#).

## Produci output strutturati

Per garantire formati di output coerenti e strutturati, puoi utilizzare output strutturati, inclusi formati come XML, JSON, Markdown o utilizzare la funzionalità di utilizzo degli strumenti.

- Questo approccio consente ai sistemi a valle di comprendere e analizzare in modo più efficace gli output generati dal modello.

- Fornendo istruzioni esplicite al modello, le risposte vengono generate in modo tale da aderire a uno schema predefinito.

Ad esempio, se il parser downstream prevede convenzioni di denominazione specifiche per le chiavi in un oggetto JSON, è necessario specificare lo schema di risposta alla fine del prompt. Inoltre, se preferisci che le risposte siano in formato JSON senza alcun testo di preambolo, istruisci il modello di conseguenza. Cioè, dichiarate esplicitamente Please, generate solo l'output JSON. NON fornire alcun preambolo. per garantire un output pulito.

#### Tip

- Osserviamo la migliore aderenza ai requisiti di formato dei dati quando sono definiti nello schema stesso anziché attraverso l'uso di esempi (ad esempio, la specificazione delle date nel formato). YYYY/MM/DD
- Per output JSON semplici con un massimo di 10 chiavi, puoi trovare lo schema seguente. Per schemi più complessi, ti consigliamo di definire lo schema tramite uno strumento. L'uso degli strumenti sfrutta una tecnica chiamata decodifica vincolata che aumenterà l'aderenza del modello a questi schemi complessi.

## Schemi di formattazione comuni

Di seguito sono riportati alcuni esempi di schemi di formattazione comuni.

### 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 )
```

```
"""
```

Precompila il contenuto dell'assistente

Se state producendo un output strutturato in modalità non ragionata, potete modificare la risposta del modello precompilando il contenuto dell'assistente.

Il preriempimento migliora la coerenza del formato di output in modalità non ragionata. Consente di indirizzare le azioni del modello, ignorare i preamboli e applicare formati di output specifici come JSON e XML. Ad esempio, se precompilate il contenuto dell'assistente con `{ or `` ` ` } json`, tale input guida il modello a generare l'oggetto JSON senza informazioni aggiuntive.

Tip

Se state cercando esplicitamente di estrarre JSON, uno schema comune consiste nel precompilare ``` ` ` } json` e aggiungere una sequenza di interruzioni. ``` ` `` Ciò garantisce che il modello produca un oggetto JSON che può essere analizzato a livello di codice.

Example Precompila i contenuti dell'assistente

Il codice seguente dimostra come precompilare con le API:

```
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())

```

Specificate uno strumento da utilizzare per schemi complessi

Un altro approccio consiste nell'utilizzare strumenti per forzare uno schema specifico per la risposta del modello includendo lo schema JSON pydantic nella sezione dello schema di utilizzo degli strumenti. Puoi specificare la scelta dello strumento nello schema fornito e la risposta di Amazon Nova sarà strutturata in base allo strumento selezionato. [Per saperne di più su come sfruttare l'uso degli strumenti, consulta Tool Use.](#)

Esempi

Esempio 1: aggiungere uno schema di output

L'aggiunta della sezione Schema di output con lo schema appropriato fa sì che il modello preferisca adattarsi a tale schema. Tuttavia, l'output del modello non è deterministico e può variare rispetto allo schema di output.

Unspecific Prompt

Utente:

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.

Assistente:

```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

Utente:

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"
}]
```

Assistente:

```
[
 {
 "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."
}
]
```

## Esempio 2: precompila la risposta del modello

Un altro approccio prevede la precompilazione della risposta del modello includendo il testo iniziale desiderato nel messaggio dell'assistente. In questo caso, la risposta del modello di Amazon Nova continuerà dal punto in cui è stato interrotto il messaggio dell'assistente.

Suggerimento: la precompilazione è valida solo quando il ragionamento non è abilitato.

Utente:

```
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.
```

Assistente (precompilazione):

```
```json
```

Assistente:

```
{  
  "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."
}
]
````
```

### Esempio 3: specifica uno strumento da utilizzare

In alternativa all'utilizzo della tecnica di preriempimento per l'output strutturato, puoi combinare la funzionalità dello strumento Nova con ToolChoice. In questo esempio, il modello genererà una chiamata allo strumento che aderisce allo schema JSON fornito e richiamerà lo strumento specifico

specificato nel formato JSON completo definito. Per ulteriori informazioni, consulta [Advanced Systems](#).

Utente:

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"
 }
}
}

```

## Casi d'uso multilingue

I modelli Amazon Nova 2 sono stati formati in più di 200 lingue e ottimizzati per 15 lingue.

## Argomenti

- [Richiesta di traduzioni accurate](#)
- [Applica convenzioni di scrittura coerenti](#)

## Richiesta di traduzioni accurate

Per sfruttare questa funzionalità per le traduzioni in forma breve (poche frasi) puoi indicare al modello di tradurre il testo nella lingua di destinazione specificata.

## Example Richieste di traduzione

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}

## Applica convenzioni di scrittura coerenti

Nei linguaggi basati su caratteri, i modelli Amazon Nova 2 possono utilizzare il set di caratteri della lingua di origine. È possibile utilizzare il seguente prompt per imporre un output coerente.

## Example Applica le convenzioni di scrittura

When translating, ensure to use the correct orthography / script / writing convention of the target language, not the source language's characters

## Chiamata di strumenti

### Sistemi agentici

### Argomenti

- [Imposta i parametri di inferenza corretti](#)
- [Considera i requisiti di latenza](#)
- [Usa una formulazione intenzionale per le istruzioni di chiamata degli strumenti](#)
- [Sfrutta i comandi di «pensiero»](#)
- [Ordinazione delle chiamate agli strumenti](#)
- [Create schemi di strumenti di qualità](#)
- [Crea subagenti](#)
- [Utilizzate strumenti per input multimodali](#)
- [Fasi successive](#)

## Imposta i parametri di inferenza corretti

La chiamata degli strumenti richiede un output strutturato molto specifico del modello ed è migliorata utilizzando i seguenti parametri di inferenza:

- Modalità non ragionata: Temperatura: 0,7 e Top P: 0,9
- Modalità di ragionamento: Temperatura: 1 e Top P: 0,9

## Considera i requisiti di latenza

### Tip

I modelli Amazon Nova 2 sono in grado di effettuare chiamate tramite strumenti con ragionamento attivato e disattivato. Tuttavia, le modalità di ragionamento hanno un impatto significativo sulla latenza.

Per le applicazioni sensibili alla latenza, è necessario ottimizzare la modalità ragionamento disattivato e semplificare le chiamate agli strumenti necessarie, ove possibile. Suddividi i flussi di lavoro a più fasi in fasi distinte per ridurre la dipendenza del modello dal rigurgito di parametri non necessari.

## Usa una formulazione intenzionale per le istruzioni di chiamata degli strumenti

Nomi degli strumenti: nei sistemi di chiamata degli strumenti è comune fare riferimento agli strumenti nel prompt di sistema per indicare al modello quando chiamare uno strumento. Quando si fa riferimento agli strumenti nel prompt, si consiglia di utilizzare il nome dello strumento anziché riferimenti o esempi xml o pythonici.

## Esempio di buon riferimento allo strumento

```
Use the 'run_shell_command' tool for running shell commands
```

## Esempio di riferimento errato all'utensile

```
Call run_shell_command() to run shell commands
```



## Sfrutta i comandi di «pensiero»

Per tutti i casi d'uso in cui il pensiero è utile per richiamare gli strumenti, ti consigliamo di sfruttare la modalità di ragionamento invece di chiedere al modello di «pensare per tag» o di utilizzare uno strumento di «riflessione».

I modelli di Amazon Nova 2 sono ampiamente addestrati per la modalità di ragionamento e produrranno risultati ottimali se utilizzati in modalità di ragionamento per la catena di pensiero.

## Ordinazione delle chiamate agli strumenti

Nei casi d'uso che potrebbero richiedere l'uso simultaneo di strumenti integrati e la chiamata degli strumenti nativi, il modello preferisce chiamare prima gli strumenti integrati.

Non date istruzioni al modello in modo che agisca diversamente nel prompt. Progetta invece il tuo flusso di lavoro in modo da tenerne conto.

Ad esempio, se non desiderate che il modello utilizzi strumenti integrati, non includeteli nel flusso di lavoro in modo che il modello non li utilizzi.

## Create schemi di strumenti di qualità

Gli schemi di utensili sono uno dei punti chiave in cui è possibile richiedere la progettazione di sistemi di chiamata degli strumenti efficaci. Tuttavia, è importante considerare ciò che viene registrato nello schema dello strumento stesso, il modo in cui ogni elemento dello schema viene descritto semanticamente e il modo in cui il prompt di sistema fa riferimento agli strumenti e agli elementi dello schema nelle istruzioni di sistema.

I modelli Amazon Nova 2 sono ottimizzati per descrizioni concise negli schemi degli strumenti. Sii breve.

Lo schema degli strumenti rispetto alle linee guida dei prompt di sistema:

Includi nello schema dello strumento:

- Funzionalità di base: cosa fa lo strumento (si consigliano 20-50 parole)
- Specifiche dei parametri: descrizioni chiare di ogni parametro (circa 10 parole per parametro)
- Formati previsti: tipi di dati (come enum, int, float), campi obbligatori e intervalli di valori validi

Includi nel prompt di sistema:

- Dedica una `#Tool Usage` sezione alla logica di orchestrazione (quando e perché utilizzare strumenti specifici) e alle regole aziendali (logica condizionale, requisiti di sequenziamento e dipendenze).
- Strategie di gestione degli errori: aggiungi una `#Error Handling and Troubleshooting` sezione con le istruzioni su come rispondere a guasti o output imprevisti
- Formattazione dell'output: aggiungi dettagli su come presentare all'utente

## Esempio

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>

## Crea subagenti

Prendi in considerazione la possibilità di creare subagenti specializzati anziché un singolo agente con molti strumenti quando ti imbatti in:

- Il numero di utensili supera i 20: i set di utensili di grandi dimensioni diventano difficili da gestire e aumentano gli errori di selezione
- Domini funzionali distinti: gli strumenti si raggruppano naturalmente in categorie separate (ad esempio recupero dei dati, elaborazione o reportistica)
- Schemi complessi: quando la profondità dei parametri supera i 3-4 livelli o gli strumenti hanno interdipendenze complesse
- Durata della conversazione: i flussi di lavoro che superano regolarmente i 15-20 turni possono avvalersi di subagenti specializzati
- Degrado delle prestazioni: se si osserva una diminuzione della precisione nella selezione degli strumenti o un aumento della latenza

### Tip

I server MCP sono dotati di strumenti e schemi che non puoi controllare. Includi solo gli strumenti necessari al flusso di lavoro per completare l'attività richiesta.

## Utilizzate strumenti per input multimodali

Per le attività multimodali, non abbiamo osservato una maggiore precisione nell'utilizzo di strumenti per attività strutturate (come l'estrazione o la generazione di timestamp).

Ti consigliamo invece di consultare le sezioni pertinenti nella sezione Richiesta di input multimodali per scoprire come richiedere correttamente il modello utilizzando i modelli forniti.

### Fasi successive

- Per i prompt multimodali, vedere. [Richiesta di ingressi multimodali](#)

## Richiesta di ingressi multimodali

Le seguenti sezioni forniscono indicazioni per la comprensione di immagini e video. Per suggerimenti relativi all'audio, consultate la sezione. [the section called “Istruzioni per le conversazioni vocali”](#)

# Linee guida multimodali generali

## Istruzioni per l'utente e istruzioni di sistema

Per i casi d'uso relativi alla comprensione multimodale, ogni richiesta deve includere il testo del prompt dell'utente. I prompt di sistema, che possono contenere solo testo, sono facoltativi.

I prompt di sistema possono essere utilizzati per specificare un personaggio per il modello e per definire la personalità generale e lo stile di risposta, ma non devono essere utilizzati per la definizione dettagliata delle attività o per istruzioni di formattazione dell'output.

Includi la definizione delle attività, le istruzioni e i dettagli di formattazione nel prompt dell'utente per avere un effetto più efficace rispetto al prompt di sistema per i casi d'uso multimodali.

## Ordine dei contenuti

Una richiesta di comprensione multimodale inviata ad Amazon Nova deve contenere uno o più file e un prompt utente. Il prompt di testo dell'utente deve essere l'ultimo elemento del messaggio, sempre dopo il contenuto dell'immagine, del documento o del video.

```
message = {
 "role": "user",
 "content": [
 { "document|image|video|audio": {...} },
 { "document|image|video|audio": {...} },
 ...
 { "text": "<user prompt>" }
]
}
```

Nei casi in cui desideri fare riferimento a file specifici dall'interno del prompt utente, utilizza gli elementi «testo» per definire le etichette che precedono ogni blocco di file.

```
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>" }
]
}
```

## Comprensione di documenti e immagini

Le seguenti sezioni forniscono indicazioni su come creare istruzioni per attività che richiedono la comprensione o l'analisi di immagini e documenti.

### Estrazione di testo dalle immagini

I modelli Amazon Nova possono estrarre testo dalle immagini, una funzionalità denominata Optical Character Recognition (OCR). Per ottenere risultati ottimali, assicurati che l'immagine che fornisci al modello abbia una risoluzione sufficientemente alta da rendere i caratteri di testo facili da distinguere.

Per i casi d'uso relativi all'estrazione di testo, consigliamo la seguente configurazione di inferenza:

- temperatura: impostazione predefinita (0,7)
- TopP: impostazione predefinita (0,9)
- Non abilita il ragionamento

I modelli Amazon Nova possono estrarre testo in formato Markdown, HTML o LaTeX. Si consiglia il seguente modello di prompt utente:

```
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.
```

L'output è racchiuso in recinzioni di codice Markdown complete o parziali (). ```` Puoi rimuovere i recinti di codice usando un codice simile al seguente:

```
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()
```

## Estrazione di informazioni strutturate da immagini o testo

I modelli Amazon Nova possono estrarre informazioni dalle immagini in formato JSON analizzabile automaticamente, un processo denominato Key Information Extraction (KIE). Per eseguire KIE, fornisci quanto segue:

- Uno schema JSON. Una definizione formale dello schema che segue la specifica dello schema JSON.
- Uno o più dei seguenti: Un file di documento o un'immagine o un testo del documento

Il documento o l'immagine devono sempre essere inseriti prima della richiesta dell'utente.

Per i casi d'uso di KIE, raccomandiamo la seguente configurazione di inferenza:

- temperatura: 0
- Ragionamento: il ragionamento non è necessario, ma può migliorare i risultati quando si utilizzano input di sole immagini o schemi complessi.

## Modelli di prompt

### Inserimento solo di documenti o immagini

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}
```

## Inserimento di solo testo

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}
```

## Documento o immagine e immissione di testo

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}
```

## Rilevamento degli oggetti e della loro posizione nelle immagini

I modelli Amazon Nova 2 offrono la possibilità di identificare gli oggetti e la loro posizione all'interno delle immagini, un'attività a volte chiamata messa a terra delle immagini o localizzazione degli oggetti. Le applicazioni pratiche includono l'analisi e l'etichettatura delle immagini, l'automazione dell'interfaccia utente, la modifica delle immagini e altro.

Indipendentemente dalla risoluzione di input dell'immagine e dalle proporzioni, il modello utilizza uno spazio di coordinate che divide l'immagine in 1.000 unità in orizzontale e 1.000 unità in verticale, con la posizione x:0 y:0 nella parte superiore sinistra dell'immagine.

I riquadri di delimitazione sono descritti utilizzando il formato [x1, y1, x2, y2] che rappresenta rispettivamente sinistra, superiore, destra e parte inferiore. Le coordinate bidimensionali sono rappresentate utilizzando il formato. [x, y]

Per i casi d'uso del rilevamento di oggetti, consigliamo i seguenti valori dei parametri di inferenza:

- temperatura: 0
- Non abilita il ragionamento

Modelli di prompt: rilevamento generale degli oggetti

Consigliamo i seguenti modelli di prompt utente.

Rilevamento di più istanze con riquadri di delimitazione:

```
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.
```

Rilevamento di una singola regione con riquadro di delimitazione:

```
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.
```

Rilevamento di più istanze con punti centrali:

```
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.
```

Rilevamento di una singola regione con punto centrale:



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.

### Analisi dell'output del modello:

Ciascuno dei prompt consigliati sopra produrrà una stringa separata da virgole contenente una o più descrizioni dei riquadri di delimitazione in una forma simile alla seguente. Potrebbe esserci qualche leggera variazione nel formato «.» è incluso alla fine della stringa. Ad esempio, [356, 770, 393, 872], [626, 770, 659, 878].

È possibile analizzare le informazioni sulle coordinate generate dal modello utilizzando un'espressione regolare, come mostrato nel seguente esempio di codice Python.

### Esempio di codice

```
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)
]
```

### Esempio di codice

Per rimappare le coordinate normalizzate di un riquadro di delimitazione allo spazio delle coordinate dell'immagine di input, puoi usare una funzione simile al seguente esempio di Python.

```
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,
]
```

## Modelli di prompt: rilevamento di più classi di oggetti con posizioni

Per identificare più classi di elementi in un'immagine, è possibile includere un elenco di classi nel prompt utilizzando uno dei seguenti approcci di formattazione.

Per le classi di uso comune che è probabile che il modello comprenda bene, elenca i nomi delle classi (senza virgolette) tra parentesi quadre:

```
[car, traffic light, road sign, pedestrian]
```

Per le classi che presentano sfumature, non comuni o che provengono da domini specializzati con cui il modello potrebbe non avere familiarità, includi una definizione per ogni classe tra parentesi. Poiché questo compito è impegnativo, aspettatevi un peggioramento delle prestazioni del modello.

```
[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)]
```

Utilizza uno dei seguenti modelli di prompt utente a seconda del formato di output JSON che preferisci.

### Opzione Prompt 1

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]
 },
 ...
]
```

## Opzione Prompt 2

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]
 },
 ...
]
```

## Opzione Prompt 3

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], ...],
 ...
}
```

## Opzione Prompt 4

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], ...]
 },
 ...
]
```

## Analisi dell'output del modello

L'output verrà codificato come JSON che può essere analizzato con qualsiasi libreria di analisi JSON.

Modelli di prompt: rilevamento dei limiti dell'interfaccia utente tramite screenshot

Consigliamo i seguenti modelli di prompt utente.

Rilevamento della posizione degli elementi dell'interfaccia utente in base a un obiettivo:

```
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.
```

Rilevamento della posizione degli elementi dell'interfaccia utente in base al testo:

```
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.
```

Analisi dell'output del modello:

Per ciascuno dei prompt di rilevamento dei limiti dell'interfaccia utente di cui sopra, puoi analizzare le informazioni sulle coordinate generate dal modello utilizzando un'espressione regolare, come mostrato nell'esempio di codice Python di seguito.

Esempio di codice

```
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)
]
```

## Comprensione dei video

Le sezioni seguenti forniscono indicazioni su come creare istruzioni per attività che richiedono la comprensione o l'analisi di video.

### Riepilogo dei video

I modelli Amazon Nova possono generare riepiloghi di contenuti video.

Per i casi d'uso di riepilogo video, consigliamo i seguenti valori dei parametri di inferenza:

- temperatura: 0
- Alcuni casi d'uso possono trarre vantaggio dall'abilitazione del ragionamento basato sui modelli

Non è richiesto alcun modello di prompt specifico. Il prompt dell'utente dovrebbe specificare chiaramente gli aspetti del video che ti interessano. Ecco alcuni esempi di istruzioni efficaci:

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?

### Generazione di didascalie dettagliate per i video

I modelli Amazon Nova possono generare didascalie dettagliate per i video, un'attività denominata didascalia densa.

Per i casi d'uso dei sottotitoli video, consigliamo i seguenti valori dei parametri di inferenza:

- temperatura: 0
- Alcuni casi d'uso possono trarre vantaggio dall'abilitazione del ragionamento basato sui modelli

Non è richiesto alcun modello di prompt specifico. Il prompt dell'utente dovrebbe specificare chiaramente gli aspetti del video che ti interessano. Ecco alcuni esempi di istruzioni efficaci:

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.

## Analisi dei filmati video di sicurezza

I modelli Amazon Nova possono rilevare eventi nei filmati di sicurezza.

Per i casi d'uso di filmati di sicurezza, consigliamo i seguenti valori dei parametri di inferenza:

- temperatura: 0
- Alcuni casi d'uso possono trarre vantaggio dall'abilitazione del ragionamento basato sui modelli

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.

## Estrazione di eventi video con timestamp

I modelli Amazon Nova possono identificare i timestamp relativi agli eventi in un video. Puoi richiedere che i timestamp siano formattati in secondi o in formato MM:SS. Ad esempio, un evento che si verifica a 1 minuto e 25 secondi nel video può essere rappresentato come o. 85 01:25

In questo caso d'uso, consigliamo i seguenti valori dei parametri di inferenza:

- temperatura: 0
- Non usare il ragionamento

Ti consigliamo di utilizzare istruzioni simili alle seguenti:

#### Identificazione dell'ora di inizio e fine di un evento

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]]`

#### Identificazione delle ricorrenze multiple di un evento

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]]`

#### Generazione di un registro di segmenti video con timestamp

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.

## Classificazione dei video

Puoi utilizzare i modelli Amazon Nova per classificare i video in base a un elenco predefinito di classi fornite da te.

In questo caso d'uso, consigliamo i seguenti valori dei parametri di inferenza:

- temperatura: 0
- Il ragionamento non dovrebbe essere usato

Utilizza il seguente modello di prompt:

```
What is the most appropriate category for this video? Select your answer from the
options provided:
{class1}
{class2}
{...}
```

Esempio:

```
What is the most appropriate category for this video? Select your answer from the
options provided:
Arts
Technology
Sports
Education
```

## Moderazione dei contenuti

Questa guida fornisce le best practice per richiedere ai modelli Amazon Nova di eseguire la moderazione dei contenuti utilizzando lo [MLCommons® AILuminate Assessment Standard](#), un framework completo con 12 categorie di pericolo per la sicurezza dell'IA. Sebbene questa guida utilizzi lo MLCommons standard come esempio per illustrare le migliori pratiche, le tecniche di suggerimento funzionano con qualsiasi categoria e definizione di moderazione dei contenuti in formato libero o personalizzabile da te specificata.

## Principi chiave

- Utilizza prompt strutturati (XML, JSON) o in formato libero in base al tuo caso d'uso



- Modera qualsiasi contenuto testuale: conversazioni, articoli, post sui social media, commenti, recensioni e altro
- Fornisci definizioni politiche chiare
- Richiedi spiegazioni per motivi di trasparenza

## Configurazione consigliata

Per le attività di moderazione dei contenuti, consigliamo la seguente configurazione di inferenza:

- Temperatura: utilizza il valore predefinito di 0,7.
- Top P: utilizza il valore predefinito di 0,9.
- Ragionamento: disabilita il ragionamento per la moderazione dei contenuti per ridurre la latenza.

## MLCommons tassonomia universale

Lo standard definisce 12 categorie di pericolo:

MLCommons AILuminate categorie di pericolo

| Categoria                       | Definizione                                                                            | Sottocategorie chiave                                                                                                               |
|---------------------------------|----------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------|
| Crimini violenti                | Contenuti che consentono, incoraggiano o sostengono la commissione di crimini violenti | Violenza di massa, omicidio, aggressione fisica, abuso domestico, terrore, abuso di animali                                         |
| Crimini non violenti            | Contenuti che abilitano, incoraggiano o sostengono attività criminali non violente     | Traffico di manodopera, frode, furto, incendio doloso, reati legati al traffico di droga, reati legati alle armi, reati informatici |
| Reati legati al sesso           | Contenuti che abilitano, incoraggiano o sostengono i reati a sfondo sessuale           | Traffico sessuale, violenza sessuale, molestie sessuali, contenuti intimi non consensuali, bestialità                               |
| Sfruttamento sessuale infantile | Contenuti che contengono, descrivono, abilitano, incoraggiano                          | Rapporti inappropriati con bambini, abuso sessuale di minori, CSAM                                                                  |

| Categoria                 | Definizione                                                                                     | Sottocategorie chiave                                                                                                |
|---------------------------|-------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------|
|                           | o sostengono l'abuso sessuale di minori                                                         |                                                                                                                      |
| CBRNE                     | Contenuti che consentono, incoraggiano o approvano la creazione di armi di distruzione di massa | Armi chimiche, armi biologiche, armi radiologiche, armi nucleari, esplosivi ad alto rendimento                       |
| Suicidio e autolesionismo | Contenuti che abilitano, incoraggiano o promuovono l'autolesionismo intenzionale                | Suicidio, autolesionismo, disturbi alimentari, sfide pericolose                                                      |
| Odio                      | Contenuti che sminuiscono o disumanizzano le persone sulla base di caratteristiche protette     | Commenti umilianti, che infliggono danni, esclusione e isolamento physical/emotional                                 |
| Consulenza specializzata  | Consulenza non qualificata in settori sensibili senza esclusioni di responsabilità appropriate  | Consulenza finanziaria, consulenza medica, consulenza legale, consulenza elettorale, reclami relativi alla sicurezza |
| Privacy                   | Contenuti contenenti informazioni personali sensibili non pubbliche                             | Sicurezza fisica (indirizzi), sicurezza digitale (credenziali), sicurezza finanziaria (numeri di conto)              |
| Proprietà intellettuale   | Contenuti che violano o incoraggiano la violazione dei diritti di proprietà intellettuale       | Violazione del copyright, violazione del marchio, violazione del brevetto                                            |
| Diffamazione              | Contenuti falsi in modo verificabile e suscettibili di danneggiare la reputazione di qualcuno   | Diffamazione, calunnia, denigrazione                                                                                 |
| Contenuti sessuali        | Contenuti erotici tra cui pornografia e cybersesso                                              | Pornografia (descrizioni sessuali grafiche), chat erotica diretta                                                    |

Fonte: MLCommons® Alluminate Assessment Standard (documentazione)

## Esempi di suggerimenti

### Formato strutturato

Ideale per sistemi automatizzati che richiedono un output analizzabile. Questi esempi utilizzano il few-shot learning, in cui si forniscono esempi di coppie input-output nel prompt per guidare le risposte del modello. Gli esempi seguenti includono un'unica dimostrazione, ma puoi includere più esempi per migliorare la precisione per il tuo caso d'uso specifico.

### Struttura (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>
```

**Struttura (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."
}
```

Esempio di richiesta e risposta di moderazione dei contenuti

**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>

## Moderazione dei contenuti in formato libero

I prompt in formato libero possono assumere molte strutture diverse oltre agli esempi riportati di seguito. Gli esempi seguenti utilizzano intenzionalmente diversi stili di formattazione per illustrare la flessibilità dei prompt in formato libero. È possibile adattare la struttura, la formulazione e il formato in base al caso d'uso specifico.

## Esempio 1: Yes/No domanda (suicidio e autolesionismo)

### Example Moderazione dei contenuti Sì/No

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.

## Esempio 2: identificazione e ragionamento della categoria (odio)

### Example Identificazione della categoria (moderazione dei contenuti)

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.

### Esempio 3: valutazione della gravità (privacy)

#### Example Valutazione della gravità (moderazione dei contenuti)

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.
```



# Codice e risoluzione dei problemi

Questo capitolo fornisce esempi di codice e linee guida per la risoluzione dei problemi per aiutarti a lavorare in modo efficace con i modelli Amazon Nova.

## Libreria di codici

Questa sezione fornisce esempi di codice per le operazioni più comuni di Amazon Nova che utilizzano l'API Converse o l' InvokeModel API.

## Esempi di API Converse

### Richiesta di base

Invia una richiesta di testo di base ai modelli Amazon Nova utilizzando l'API Converse.

### 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\nEND'. cant be empty"}],
 }
],
 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)

```

## Input multimodale tramite asset incorporato

Elabora i contenuti multimodali incorporando dati di documenti, immagini, video o audio direttamente nella richiesta. Questo esempio utilizza dati di immagine. Per dettagli sulla struttura dei contenuti per altre modalità, consulta [ContentBlock i dettagli nella documentazione dell'API Amazon Bedrock](#).

### 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)

```

## Ingresso multimodale tramite URI S3

Elabora contenuti multimodali facendo riferimento a documenti, immagini, video o file audio archiviati in S3. Questo esempio utilizza un riferimento a un'immagine. Per dettagli sulla struttura dei contenuti per altre modalità, consulta [ContentBlock i dettagli nella documentazione dell'API Amazon Bedrock](#).

### 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)
```

## Pensiero esteso (ragionamento)

Abilita il pensiero esteso per attività complesse di risoluzione di problemi.

### 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

```

## Strumento integrato: Nova Grounding con citazioni

Usa Nova Grounding per recuperare informazioni in tempo reale dal Web con citazioni.

## 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)
```

## Strumento integrato: Code Interpreter

Usa lo strumento Code Interpreter per eseguire codice Python per calcoli e analisi dei dati.

### 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)

```

## Utilizzo degli strumenti

Definisci strumenti personalizzati per il modello da utilizzare durante la conversazione.

### 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 Esempi di API

Gli esempi seguenti si concentrano sulle poche aree chiave in cui le strutture di richiesta e risposta dell'API Invoke differiscono leggermente da quelle dell'API Converse. Nella maggior parte degli altri modi, le due APIs sono compatibili, quindi dovresti essere in grado di adattare facilmente gli esempi di API Converse di cui sopra per farli funzionare con l'API. InvokeModel

### Richiesta di base

Invia una richiesta di testo di base ai modelli Amazon Nova 2 utilizzando l' InvokeModel API.

## 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 con ragionamento

Utilizza l' InvokeModel API con il ragionamento abilitato per la risoluzione di problemi complessi.

### 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)
```

## Risoluzione dei problemi

Questa sezione fornisce soluzioni ai problemi più comuni relativi all'utilizzo dei modelli Amazon Nova.

### Autenticazione e configurazione

#### Autorizzazioni mancanti

Sintomi: impossibile accedere ai modelli o alle funzionalità di Nova

Soluzione::

- Assicurati che il tuo ruolo IAM AmazonBedrockFullAccess disponga delle autorizzazioni appropriate

- Richiedi l'accesso a un modello specifico tramite la console Amazon Bedrock
- Verifica le autorizzazioni per l'accesso al modello e l'utilizzo degli strumenti

## Accesso al modello negato

Sintomi: la richiesta di accesso al modello non riesce

Soluzione::

- Richiedi l'accesso a un modello specifico tramite la console Amazon Bedrock
- Verifica che al tuo account sia stato concesso l'accesso al modello richiesto
- Verifica la disponibilità regionale del modello

## Problemi di disponibilità a livello regionale

Sintomi: funzionalità non disponibile nella regione selezionata

Soluzione::

- Web Grounding è disponibile solo nelle regioni degli Stati Uniti con profili CRIS statunitensi
- Verifica che il modello e le funzionalità siano disponibili nella regione selezionata
- Passa a una regione supportata, se necessario

## Configurazione del timeout

Sintomi: scadono le richieste prima del completamento

Causa: il timeout predefinito è troppo breve per operazioni complesse

Soluzione: configurare le impostazioni di timeout esteso

```
from botocore.config import Config

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

)

 **Note**

Le richieste di inferenza di Amazon Nova possono richiedere fino a 60 minuti per operazioni complesse.

## Problemi di risposta delle API

Comprensione dei motivi dell'interruzione:

`end_turn`

Completamento normale. Non è richiesta alcuna operazione.

`max_tokens`

Limite di token raggiunto.

Soluzione: aumentare `maxTokens` il parametro `inferenceConfig`.

`content_filtered`

Il contenuto ha violato AWS la politica sull'IA responsabile.

Soluzione: rivedi e modifica i tuoi input per conformarti alle politiche sui contenuti.

`malformed_model_output`

Formato di output non valido.

Soluzione: controlla lo schema di output e i vincoli; verifica che lo schema JSON sia formattato correttamente.

`malformed_tool_use`

Formato di chiamata dell'utensile non valido.

Soluzione: verificate che le definizioni degli utensili corrispondano allo schema previsto; verificate che i parametri di input dell'utensile siano formattati correttamente.

`servizio_non disponibile`

Servizio utensili integrato non disponibile.

Soluzione: riprova la richiesta dopo un breve ritardo; controlla la dashboard dello stato AWS del servizio.

invalid\_query

Interrogazione non valida sullo strumento integrato.

Soluzione: rivedete il formato e i parametri della query; assicuratevi che la query soddisfi i requisiti dello strumento.

max\_tool\_invocations

Tentativi dello strumento esauriti.

Soluzione: semplificate l'operazione o suddividetela in fasi più piccole; esaminate i messaggi di errore dello strumento per problemi specifici.

## Errori in modalità ragionamento

Risposte troncate con un elevato sforzo di ragionamento

Soluzione: per un maggiore sforzo di ragionamento, deimposta questi parametri: `temperature`, `topP`, `maxToken`. Ciò consente al modello di utilizzare impostazioni ottimali per attività di ragionamento complesse.

Token insufficienti per il ragionamento

Errore: «MaxTokens è insufficiente»

Soluzione: riprova automaticamente con un limite maggiore

```
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

```

## Problemi di utilizzo degli strumenti

### Errori di convalida dello schema

#### Errori di convalida dello schema degli strumenti

Soluzione::

- Limita gli schemi JSON a due livelli di nidificazione per ottenere prestazioni ottimali
- Assicurati che tutti i campi obbligatori siano definiti correttamente
- Convalida lo schema rispetto alle specifiche dello schema JSON

#### Il modello non utilizza correttamente gli strumenti

Soluzione::

- Assicurati che il nome dello strumento ne descriva chiaramente lo scopo
- Fornire una descrizione dettagliata della funzionalità dello strumento
- Definisci in modo esplicito lo schema di input con descrizioni chiare dei parametri
- Includi esempi nella descrizione quando utile

#### Comportamento incoerente di chiamata degli strumenti

Soluzione: impostate la temperatura su 0 per la chiamata dello strumento:

```

inferenceConfig={
 "temperature": 0,
 "maxTokens": 10000
}

```

```
}
```

Ciò consente una decodifica avida per un uso più affidabile degli strumenti.

### Conflitti nella scelta degli strumenti

Problema: errore durante l'utilizzo di strumenti personalizzati con ricerca Web o interprete di codice

Soluzione: non includete un ToolSpec personalizzato con `nomenova_grounding`: ciò è in conflitto con lo strumento di sistema. Utilizzate invece la configurazione degli strumenti di sistema:

```
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", ...}
}]
}
```

## Problemi relativi al Web Grounding

### Problemi di controllo degli accessi

Problema: Web Grounding and Code Interpreter non funzionano

Soluzione: assicurati che la tua policy IAM includa:

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

```
]
}
```

## Problemi relativi alla politica di controllo dei servizi

Problema: Web Grounding bloccato da SCP

Soluzione: se disponete di politiche di controllo dei servizi con `aws:requestedRegion` condizioni, aggiornatele per consentire la funzionalità Web Grounding nella regione «non specificata».

## Limitazioni dell'elaborazione dei file multimediali

### Scarsa comprensione dei contenuti multilingue nelle immagini/video

Limitazione: i modelli Nova hanno una comprensione limitata dei contenuti multilingue nei media visivi

Soluzione alternativa:

- Fornisci traduzioni di testo insieme alle immagini
- Se possibile, utilizza input basati su testo per contenuti multilingue

### Identificazione delle persone

Problema: la modella si rifiuta di identificare le persone nelle immagini

Comportamento previsto: le modelle si rifiuteranno di identificare o nominare le persone nelle immagini, nei documenti o nei video per motivi di privacy e sicurezza

Soluzione alternativa: chiedi informazioni sulle caratteristiche generali o sul contesto anziché sulle identità specifiche

### Limitazioni del ragionamento spaziale

Problema: localizzazione o analisi del layout imprecise

Limitazione: capacità limitate per un ragionamento spaziale preciso

Soluzione alternativa:

- Utilizza il rilevamento dei bounding box per la localizzazione degli oggetti
- Fornisci punti di riferimento chiari nelle tue istruzioni



- Suddividi le interrogazioni spaziali complesse in componenti più semplici

### Testo di piccole dimensioni in immagini/video

Problema: non è possibile leggere testo di piccole dimensioni nei file multimediali

Soluzione::

- Ritaglia le immagini per concentrarti sulle sezioni di testo pertinenti
- Aumenta la risoluzione dei file multimediali di origine
- Fornisci il testo separatamente, se disponibile

## Gestione di documenti e file

### Contenuti non supportati

Problema: l'elaborazione del PDF non riesce

Cause:

- PDFs con profili di colore CMYK
- PDFs contenente immagini SVG

Soluzione::

- Converti in PDFs profilo di colore RGB
- Rasterizza le immagini SVG prima di includerle PDFs

### Stima dei token

Problema: utilizzo imprevisto del token con PDFs

Linea guida: stima circa 2.560 token per pagina PDF standard da 8,5 × 11"

Soluzione: regolate di conseguenza in base alla lunghezza del documento maxTokens

# Informazioni di riferimento su API e SDK

Questa sezione fornisce la documentazione tecnica di riferimento completa per Amazon Nova APIs e SDKs.

## Argomenti

- [Schema di richiesta e risposta](#)
- [Riferimento SDK](#)

## Schema di richiesta e risposta

Lo schema di richiesta è quasi identico tra l'API Invoke e l'API Converse. La differenza principale è il modo in cui i dati binari (immagini, video, audio) vengono codificati: l'API Converse utilizza array binari mentre l'API Invoke utilizza stringhe con codifica Base64.

## Struttura completa delle richieste

Di seguito viene illustrata la struttura completa delle richieste per i modelli Amazon Nova. Tutti i campi sono facoltativi a meno che non siano contrassegnati come obbligatori:

```
{
 "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"
 }
 }
}

```

Parametri chiave della richiesta:

- **system**: prompt di sistema che fornisce contesto e istruzioni

- `messages`: La serie di conversazioni varia in base al ruolo (utente o assistente) e al contenuto
- `inferenceConfig`: controlla il comportamento di output del modello (temperatura, token e così via).
- `toolConfig`: specifiche degli strumenti per la chiamata di funzioni

#### Note

Quando si utilizza l'API Converse, è necessario inserire `reasoningConfig` i parametri `topK` and `additionalModelRequestFields` anziché `inferenceConfig`.

Le seguenti sezioni forniscono spiegazioni dettagliate di ciascun parametro di richiesta:

#### sistema

`system` (facoltativo): il prompt di sistema per la richiesta. Un prompt di sistema fornisce contesto e istruzioni ad Amazon Nova, ad esempio per specificare un obiettivo o un ruolo particolare.

#### messages

`messages`— (Obbligatorio) L'array di messaggi di input contenente i turni di conversazione.

- `role`— (Obbligatorio) Il ruolo del turno di conversazione. I valori validi sono `user` e `assistant`. Il primo messaggio deve sempre utilizzare il `user` ruolo.
- `content`— (Obbligatorio) Una serie di blocchi di contenuto. Ogni blocco specifica un tipo di contenuto (`text`, `imagevideo`, `oaudio`):
  - `text`— Contenuto testuale per il turno di conversazione. Se combinato con un'immagine o un video, interpretato come testo di accompagnamento.
  - `image`— (Non supportato per Nova 2 Lite) Contenuto dell'immagine con:
    - `format`— (Obbligatorio) Formato dell'immagine: `jpegpng`, `webp`, o `gif`
    - `source.bytes`— (Obbligatorio) Dati di immagine come array binario (Converse API) o stringa Base64 (Invoke API)
  - `video`— (Non supportato per Nova 2 Lite) Contenuti video con:
    - `format`— (Obbligatorio) Formato video: `mkv`, `mov`, `mp4`, `webm`, `three_gp`, `flv`, `mpeg`, `mpg`, o `wmv`
    - `source`— (Obbligatorio) Sorgente video tramite URI S3 (`s3Location.uri` opzionale `bucketOwner`) o file `byte () bytes`

- **audio**— (Amazon Nova Sonic e solo) Contenuti audio con:
  - **format**— (Obbligatorio) Formato audio: mp3opus,wav,aac,flac,, mp4ogg, o mkv
  - **source**— (Obbligatorio) Sorgente audio tramite URI S3 o byte di file

## inferenceConfig

**inferenceConfig**— (Opzionale) Parametri di configurazione che controllano la generazione dell'output del modello.

- **maxTokens**— (Facoltativo) Numero massimo di token da generare prima dell'arresto. I modelli Amazon Nova potrebbero interrompersi prima di raggiungere questo limite. Il valore massimo è 5.000. Se non specificato, utilizza un valore predefinito dinamico basato sul contesto della richiesta.
- **temperature**— (Facoltativo) Casualità nelle risposte. Intervallo valido: 0,00001-1 (predefinito: 0,7). I valori più bassi producono un output più deterministico.
- **topP**— (Facoltativo) Soglia di campionamento del nucleo. Amazon Nova campiona token la cui probabilità cumulativa raggiunge. **topP** Intervallo valido: 0-1 (impostazione predefinita: 0,9). Regola una delle due temperature o **topP** non entrambe.
- **topK**— (Facoltativo) Esamina solo i migliori token K. Rimuove le risposte a bassa probabilità. Intervallo valido: 0-128 (impostazione predefinita: non utilizzato).

### Note

Per l'API Converse, passa. **topK additionalModelRequestFields**

- **stopSequences**— (Facoltativo) Matrice di stringhe che interrompono la generazione quando vengono rilevate.
- **reasoningConfig**— (Solo Amazon Nova Sonic) Configurazione del ragionamento:
  - **type**— (Facoltativo) **enabled** o **disabled** (impostazione predefinita:) **disabled**
  - **maxReasoningEffort**— Sforzo computazionale:low,medium, ohigh. Con low emedium, il ragionamento scorre in modo incrementale; high restituisce il ragionamento in una parte finale.

### Note

Per l'API Converse, passa. **reasoningConfig additionalModelRequestFields**

## toolConfig

**toolConfig**— (Facoltativo) Configurazione dello strumento secondo [ToolConfiguration lo schema](#).

- **tools**— Serie di specifiche degli utensili con `name`, `description` e `inputSchema`
- **toolChoice**— (Opzionale) Controlla la selezione degli utensili:
  - **auto**— Il modello decide se e quali strumenti utilizzare
  - **any**— Il modello deve utilizzare almeno un utensile
  - **tool**— Il modello deve utilizzare l'utensile specificato per nome

## Struttura di risposta completa

Di seguito viene illustrata la struttura di risposta completa per i modelli Amazon Nova:

```
{
 "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
}
}

```

#### Motivi dello stop:

- **end\_turn**: Fine naturale della risposta
- **max\_tokens**: Raggiunto il limite MaxTokens
- **content\_filtered**: Politica sui contenuti violata
- **malformed\_model\_output**: output del modello non valido
- **malformed\_tool\_use**: output di utilizzo dello strumento non valido
- **service\_unavailable**: servizio utensili integrato irraggiungibile
- **invalid\_query**: Interrogazione non valida sullo strumento integrato
- **max\_tool\_invocations**: Tentativi dello strumento esauriti



Le seguenti sezioni forniscono spiegazioni dettagliate di ogni campo di risposta:

## output

**output**— (Obbligatorio) Contiene il messaggio di risposta del modello.

- **message**— (Obbligatorio) Il messaggio di risposta dell'assistente con ruolo e array di contenuti.
- **content**— (Obbligatorio) Matrice di blocchi di contenuto che può includere:
  - **reasoningContent**— (Facoltativo) Restituito se il ragionamento era abilitato. Contiene il testo del ragionamento, che sarà sempre presente [REDACTED] nella risposta.
  - **toolUse**— (Facoltativo) Restituito se è stato chiamato uno strumento. Contiene l'ID di utilizzo dello strumento, il nome e gli argomenti di input.
  - **text**— (Facoltativo) Restituito se il modello ha risposto con contenuto testuale.
  - **image**— (Facoltativo, solo) Restituito se il modello ha generato un'immagine. Il formato sarà sempre PNG.

## Interrompi Reason

**stopReason**— (Obbligatorio) Indica il motivo per cui il modello ha smesso di generare output:

- **end\_turn**— Fine naturale della risposta raggiunta
- **max\_tokens**— Raggiunto il limite MaxTokens o il limite di output massimo del modello
- **content\_filtered**— Output violato AWS la politica di intelligenza artificiale responsabile
- **malformed\_model\_output**— Il modello ha prodotto un output non valido
- **malformed\_tool\_use**— Il modello ha prodotto un output di utilizzo dell'utensile non valido
- **service\_unavailable**— Il servizio utensili integrato non è stato raggiungibile
- **invalid\_query**— La query sullo strumento integrato non era valida
- **max\_tool\_invocations**— Lo strumento integrato non ha prodotto risultati validi dopo nuovi tentativi

## utilizzo

**usage**— (Obbligatorio) Informazioni sull'utilizzo del token:

- **inputTokens**— Token totali ingeriti dal modello
- **outputTokens**— Numero di token generati

- `totalTokens`— Somma dei token di input e output

metriche

`metrics`— Metriche prestazionali (obbligatorie):

- `latencyMs`— Tempo totale di completamento dell'inferenza in millisecondi

## Riferimento SDK

AWS i kit di sviluppo software (SDKs) sono disponibili per molti linguaggi di programmazione più diffusi. Ogni SDK fornisce un'API, esempi di codice e documentazione che semplificano agli sviluppatori la creazione di applicazioni nella loro lingua preferita.

| Documentazione sugli SDK                     | Esempi di codice                                              |
|----------------------------------------------|---------------------------------------------------------------|
| <a href="#">AWS SDK per C++</a>              | <a href="#">AWS Esempi di codice SDK for C++</a>              |
| <a href="#">AWS CLI</a>                      | <a href="#">AWS Esempi di codice CLI</a>                      |
| <a href="#">AWS SDK for Go</a>               | <a href="#">AWS Esempi di codice SDK for Go</a>               |
| <a href="#">AWS SDK per Java</a>             | <a href="#">AWS Esempi di codice SDK for Java</a>             |
| <a href="#">AWS SDK per JavaScript</a>       | <a href="#">AWS SDK per esempi di codice JavaScript</a>       |
| <a href="#">AWS SDK per Kotlin</a>           | <a href="#">AWS Esempi di codice SDK per Kotlin</a>           |
| <a href="#">AWS SDK per .NET</a>             | <a href="#">AWS Esempi di codice SDK for .NET</a>             |
| <a href="#">AWS SDK per PHP</a>              | <a href="#">AWS Esempi di codice SDK for PHP</a>              |
| <a href="#">AWS Strumenti per PowerShell</a> | <a href="#">AWS Strumenti per esempi di PowerShell codice</a> |
| <a href="#">AWS SDK per Python (Boto3)</a>   | <a href="#">AWS Esempi di codice SDK for Python (Boto3)</a>   |
| <a href="#">AWS SDK per Ruby</a>             | <a href="#">AWS Esempi di codice SDK for Ruby</a>             |
| <a href="#">AWS SDK per Rust</a>             | <a href="#">AWS Esempi di codice SDK per Rust</a>             |

| Documentazione sugli SDK             | Esempi di codice                                      |
|--------------------------------------|-------------------------------------------------------|
| <a href="#">AWS SDK per SAP ABAP</a> | <a href="#">AWS Esempi di codice SDK per SAP ABAP</a> |
| <a href="#">AWS SDK per Swift</a>    | <a href="#">AWS Esempi di codice SDK per Swift</a>    |

# Personalizzazione dei modelli Amazon Nova sull'intelligenza artificiale SageMaker

Puoi personalizzare i modelli Amazon Nova, inclusi i modelli Amazon Nova 2.0 migliorati, tramite [ricette](#) e addestrarli SageMaker. Queste ricette supportano tecniche come il supervised fine-tuning (SFT) e il Reinforcement Fine-Tuning (RFT), con opzioni di adattamento completo e di adattamento a basso livello (LoRa).

Il flusso di lavoro di end-to-end personalizzazione prevede fasi come l'addestramento del modello, la valutazione del modello e l'implementazione per l'inferenza. Questo approccio di personalizzazione dei modelli SageMaker offre maggiore flessibilità e controllo per ottimizzare i modelli Amazon Nova supportati, ottimizzare gli iperparametri con precisione e implementare tecniche come LoRa parameter-efficient fine-tuning (PEFT), full rank SFT, RFT e Continued Pre-Training (CPT).

## Approcci di personalizzazione

SageMaker offre due approcci per personalizzare i modelli Amazon Nova:

**Esperienza basata sull'interfaccia utente:** consente di personalizzare i modelli Amazon Nova tramite un'interfaccia semplice e guidata. Questo approccio fornisce un end-to-end flusso di lavoro che include formazione, valutazione e distribuzione senza scrivere codice. L'esperienza basata sull'interfaccia utente è ideale per la sperimentazione e proof-of-concept lo sviluppo rapidi e per gli utenti che preferiscono un flusso di lavoro visivo.

**Esperienza basata sul codice:** usa SageMaker Python SDK, Nova SDK e le ricette di formazione per personalizzare i modelli a livello di codice. Questo approccio offre una maggiore flessibilità e consente di configurare iperparametri avanzati, integrarsi con le pipeline e automatizzare i flussi di lavoro di formazione. CI/CD L'esperienza basata sul codice è consigliata per carichi di lavoro di produzione, requisiti di personalizzazione complessi e team con pratiche consolidate. MLOps

| Approccio                      | Ideale per                                         | Vantaggi principali                                                           |
|--------------------------------|----------------------------------------------------|-------------------------------------------------------------------------------|
| Basato sull'interfaccia utente | Sperimentazione, prototipazione, iterazioni rapide | Configurazione semplice, flusso di lavoro guidato, nessuna codifica richiesta |

| Approccio        | Ideale per                                       | Vantaggi principali                                                       |
|------------------|--------------------------------------------------|---------------------------------------------------------------------------|
| Basato su codice | Produzione, automazione, configurazioni avanzate | Piena flessibilità, integrazione della pipeline, controllo della versione |

## Piattaforme di personalizzazione

AWS offre tre piattaforme per personalizzare i modelli Amazon Nova, ognuna progettata per casi d'uso e requisiti diversi:

**Amazon Bedrock:** offre il percorso più semplice e veloce per la personalizzazione del modello con una configurazione minima. Bedrock gestisce automaticamente tutta la gestione dell'infrastruttura, consentendoti di concentrarti sui dati e sul caso d'uso. Questa piattaforma è ideale quando hai bisogno della massima rapidità time-to-value e preferisci un'esperienza completamente gestita.

**SageMaker lavori di formazione:** fornisce un ambiente completamente gestito per la personalizzazione dei modelli Amazon Nova in cui non è necessario creare o mantenere alcun cluster. Il servizio gestisce automaticamente tutto il provisioning, la scalabilità e la gestione delle risorse dell'infrastruttura, consentendoti di concentrarti sulla configurazione dei parametri di formazione e sull'invio del lavoro. Questa piattaforma offre un equilibrio tra facilità d'uso e flessibilità e supporta tecniche come Parameter Efficient Fine-tuning (PEFT), Full rank fine tuning e Reinforcement Fine-Tuning (RFT).

**SageMaker HyperPod—** Offre un ambiente specializzato per la formazione distribuita su larga scala, richiedendo la creazione e la gestione di cluster EKS con gruppi di istanze ristretti (). RIGs Questa piattaforma offre la massima flessibilità nella configurazione del tuo ambiente di formazione con istanze GPU specializzate e storage Amazon FSx for Lustre integrato, rendendola particolarmente adatta per scenari di formazione distribuita avanzati, sviluppo continuo di modelli e carichi di lavoro di personalizzazione su scala aziendale.

| Platform (Piattaforma) | Complessità | Flessibilità | Ideale per                                          |
|------------------------|-------------|--------------|-----------------------------------------------------|
| Amazon Bedrock         | Minimo      | Standard     | Personalizzazione più rapida, configurazione minima |

| Platform (Piattaforma)         | Complessità | Flessibilità | Ideale per                                                         |
|--------------------------------|-------------|--------------|--------------------------------------------------------------------|
| SageMaker lavori di formazione | Media       | Elevata      | Flessibilità e facilità d'uso bilanciate                           |
| SageMaker HyperPod             | Massimo     | Massimo      | Formazione distribuita su vasta scala, carichi di lavoro aziendali |

### Note

Se fornisci una chiave KMS per il tuo processo di formazione sulla personalizzazione del modello Amazon Nova per la crittografia nel bucket di output S3 di proprietà di Amazon:

- Devi fornire la stessa chiave KMS quando richiami i successivi lavori di formazione iterativi o quando chiami l' `CreateCustomModel` API Amazon Bedrock sfruttando il modello crittografato.
- L'identità che chiama l'`CreateTrainingJobAPI` (anziché il ruolo di esecuzione) deve disporre delle autorizzazioni per `CreateGrant` e `GenerateDataKey` come definito nella `Encrypt` policy chiave KMS. `RetireGrant`

## Prerequisiti generali

Il processo di personalizzazione prevede diverse fasi chiave, tra cui addestramento dei modelli, valutazione e implementazione per l'inferenza, ognuna delle quali richiede risorse e configurazioni specifiche. Prima di iniziare la personalizzazione del modello Amazon Nova su Amazon Nova SageMaker, assicurati di avere i seguenti prerequisiti generali.

- Un Account AWS Se non ne hai uno Account AWS, segui [queste istruzioni](#) per registrarti.
- [Installazione dell' AWS CLI](#) e [impostazione della configurazione](#).
- Accesso alle [ricette per la personalizzazione dei modelli Amazon Nova di base](#).
- Familiarità con i file di configurazione [YAML](#).
- Conoscenza di come utilizzare un notebook nel proprio ambiente.

- Conoscenza di come creare AWS risorse come bucket [Amazon S3](#) e ruoli IAM con le autorizzazioni appropriate.
- [Conoscenza di come addestrare un modello con SageMaker](#)
- Familiarità [SageMaker HyperPod con l'orchestrazione EKS](#).
- Familiarità con la [SageMaker HyperPod CLI](#).
- Familiarità con i [modelli di fondazione Amazon Nova](#).
- Familiarità con [i modelli e gli algoritmi di Amazon Nova disponibili per la personalizzazione](#).
- Familiarità con [l'inferenza di Amazon Bedrock](#).

## Ricette Amazon Nova

Puoi ottenere una ricetta Amazon Nova dall'archivio delle [ricette](#). Una ricetta Amazon Nova è un file di configurazione [YAML](#) che fornisce dettagli SageMaker su come eseguire il processo di personalizzazione del modello. Fornisce il nome del modello di base, imposta gli iperparametri di addestramento, definisce le impostazioni di ottimizzazione e include tutte le opzioni aggiuntive necessarie per eseguire il fine-tuning o addestrare correttamente il modello.

Puoi anche accedere alle ricette di Amazon Nova tramite SageMaker AI Monarch e accedendo al Model Hub AWS, selezionando ed esplorando i modelli Amazon Nova per trovare le ricette associate. Sia SageMaker AI Monarch che io forniamo taccuini di esempio per ogni ricetta, che includono tutti i passaggi necessari per modificare le ricette ed eseguire lavori di personalizzazione utilizzando lavori o ambienti di formazione. SageMaker SageMaker HyperPod

Per accedere alle pagine delle ricette in Amazon SageMaker Studio, il ruolo di esecuzione deve disporre delle seguenti autorizzazioni.

JSON

```
{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Effect": "Allow",
 "Action": [
 "s3:GetObject"
],
 "Resource": [
```

```
 "arn:aws:s3:::*model-customization-recipes*"
]
}
}
```

Per eseguire i taccuini di esempio durante i lavori di SageMaker formazione, utilizza una delle seguenti versioni delle immagini di SageMaker distribuzione: 2.7.1+, 2.8.0+ 3.2.1+ 3.3.0+. Questo vale sia per SageMaker AI Monarch che per.

### Argomenti

- [Recupero di ricette Amazon Nova](#)
- [Ottenere le ricette di Amazon Nova Forge](#)
- [Modelli e algoritmi disponibili](#)
- [Amazon Nova 2.0 Lite](#)

## Recupero di ricette Amazon Nova

Per ottenere una ricetta base di Amazon Nova, clona l'archivio delle [ricette](#) eseguendo il comando seguente.

```
git clone https://github.com/aws/sagemaker-hyperpod-recipes.git
```

Le ricette di base sono disponibili in [recipes\\_collection/recipes/](#).

```
cd recipes_collection/recipes/
```

Le ricette di personalizzazione di Amazon Nova si trovano nelle seguenti cartelle.

| Recipe type            | Cartella                         |
|------------------------|----------------------------------|
| SFT (Full-rank e PEFT) | <a href="#">fine-tuning/nova</a> |
| Valutazione            | <a href="#">evaluation/nova</a>  |
| CPT                    | <a href="#">training/nova</a>    |



## Ottenere le ricette di Amazon Nova Forge

Per accedere a ricette specializzate di Amazon Nova Forge per i lavori, [configura il tuo accesso ad Amazon Nova Forge](#) e segui [questo workshop](#) per configurare la versione Forge della CLI. Per SageMaker Training Jobs, AWS Console e Nova Forge SDK accederanno automaticamente alle ricette di Forge.

## Modelli e algoritmi disponibili

La tabella seguente riassume la disponibilità della personalizzazione per i modelli Amazon Nova e gli algoritmi supportati che utilizzano. SageMaker

| Nome modello         | ID modello                   | Fine-tuning | Note                                                                                                                                                                                                                                                                                                                                                                                                                             |
|----------------------|------------------------------|-------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Amazon Nova Lite 2.0 | amazon.nova-2-lite-v1:0:256k | Sì          | <ul style="list-style-type: none"><li>• SFT: accetta testo, and/or immagine o testo video come input e produce testo come output. and/or Un singolo job non può combinare testo, immagini e video nella stessa esecuzione.</li><li>• RFT: accetta testo e immagini come input per conversazioni a turno singolo e produce testo come output. Funzionalità di ottimizzazione delle ricompense migliorate.</li><li>• CPT</li></ul> |

## Amazon Nova 2.0 Lite

La tabella seguente elenca informazioni dettagliate sul riferimento alle ricette di Amazon Nova 2.0 Lite.

| Modello       | Categoria / Sottocategoria                   | Tecnica                         | Nome della ricetta                   | URI dell'immagine (Training Jobs)                                       | URI dell'immagine (SageMaker HyperPod)                                               | Istanza di calcolo               |
|---------------|----------------------------------------------|---------------------------------|--------------------------------------|-------------------------------------------------------------------------|--------------------------------------------------------------------------------------|----------------------------------|
| Nova 2.0 Lite | Addestramento                                | Formazione preliminare continua | nova_lite_2_0_p5x8_gpu_pretrain.yaml | N/D                                                                     | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-CPT-V2-latest | m1.p5.48xlarge, m1.p5en.48xlarge |
| Nova 2.0 Lite | Regolazione precisa efficiente dei parametri | Fine-tuning                     | nova_lite_2_0_p5_gpu_lora_sft.yaml   | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-TJ- | 708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo                     | m1.p5.48xlarge, m1.p5en.48xlarge |

| Modello       | Categoria / Sottocategoria | Tecnica     | Nome della ricetta            | URI dell'immagine (Training Jobs)                                                    | URI dell'immagine (SageMaker HyperPod)                                               | Istanza di calcolo               |
|---------------|----------------------------|-------------|-------------------------------|--------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------|----------------------------------|
|               |                            |             |                               | SFT-V2-latest                                                                        | o:SM-HP-SFT-V2-latest                                                                |                                  |
| Nova 2.0 Lite | Fine Tuning completo       | Fine-tuning | 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 |

| Modello       | Categoria / Sottocategoria | Tecnica     | Nome della ricetta                          | URI dell'immagine (Training Jobs)                                                    | URI dell'immagine (SageMaker HyperPod)                                                     | Istanza di calcolo                |
|---------------|----------------------------|-------------|---------------------------------------------|--------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------|-----------------------------------|
| Nova 2.0 Lite | Parametri RFT efficiente   | Fine-tuning | 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 | ml.p5.48xlarge , ml.p5en.48xlarge |

| Modello       | Categoria / Sottocategoria | Tecnica     | Nome della ricetta                  | URI dell'immagine (Training Jobs)                                                    | URI dell'immagine (SageMaker HyperPod)                                                     | Istanza di calcolo                |
|---------------|----------------------------|-------------|-------------------------------------|--------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------|-----------------------------------|
| Nova 2.0 Lite | RFT di rango completo      | Fine-tuning | 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 |

| Modello       | Categoria / Sottocategoria | Tecnica     | Nome della ricetta                                          | URI dell'immagine (Training Jobs)                                                      | URI dell'immagine (SageMaker HyperPod)                                                 | Istanza di calcolo                |
|---------------|----------------------------|-------------|-------------------------------------------------------------|----------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------|-----------------------------------|
| Nova 2.0 Lite | Porta i tuoi dati          | Valutazione | 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 | m1.p5.48xlarge , m1.p5en.48xlarge |

| Modello       | Categoria / Sottocategoria  | Tecnica     | Nome della ricetta                                         | URI dell'immagine (Training Jobs)                                                      | URI dell'immagine (SageMaker HyperPod)                                                 | Istanza di calcolo                |
|---------------|-----------------------------|-------------|------------------------------------------------------------|----------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------|-----------------------------------|
| Nova 2.0 Lite | Benchmark testuale generale | Valutazione | 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 | m1.p5.48xlarge , m1.p5en.48xlarge |

| Modello       | Categoria / Sottocategoria | Tecnica     | Nome della ricetta                      | URI dell'immagine (Training Jobs)                                                      | URI dell'immagine (SageMaker HyperPod)                                                 | Istanza di calcolo                |
|---------------|----------------------------|-------------|-----------------------------------------|----------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------|-----------------------------------|
| Nova 2.0 Lite | Valutazione RFT            | Valutazione | 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 | m1.p5.48xlarge , m1.p5en.48xlarge |



| Modello       | Categoria / Sottocategoria   | Tecnica     | Nome della ricetta                                   | URI dell'immagine (Training Jobs)                                                      | URI dell'immagine (SageMaker HyperPod)                                                 | Istanza di calcolo               |
|---------------|------------------------------|-------------|------------------------------------------------------|----------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------|----------------------------------|
| Nova 2.0 Lite | Giudice basato su LLM Rubric | Valutazione | 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 | m1.p5.48xlarge, ml.p5en.48xlarge |

## Personalizzazione di Amazon Nova su SageMaker Training Jobs

SageMaker Training Jobs è un ambiente che consente di addestrare modelli di machine learning su larga scala. Forniscono e scalano automaticamente le risorse di calcolo, caricano i dati di addestramento da fonti come Amazon S3, eseguono il codice di addestramento e archiviano gli artefatti dei modelli risultanti.

Lo scopo dell'addestramento è personalizzare il modello di base di Amazon Nova utilizzando dati proprietari. Il processo di formazione prevede in genere passaggi per preparare i dati, scegliere una [ricetta](#), modificare i parametri di configurazione nei file YAML e inviare un lavoro di formazione. Il processo di addestramento genera un checkpoint del modello addestrato in un bucket Amazon S3 gestito dal servizio. È possibile utilizzare la posizione di questo checkpoint per processi di valutazione. La personalizzazione di Nova sui lavori di formazione sull' SageMaker intelligenza

artificiale archivia gli artefatti del modello in un bucket Amazon S3 gestito dal servizio. Gli artefatti nel bucket gestito dal servizio sono crittografati con chiavi KMS gestite dall'intelligenza artificiale. SageMaker I bucket Amazon S3 gestiti dal servizio attualmente non supportano la crittografia dei dati tramite chiavi KMS gestite dal cliente.

## Best practice per la personalizzazione di Amazon Nova

### Panoramica di

Questa sezione fornisce una panoramica delle tecniche di personalizzazione e ti aiuta a scegliere l'approccio migliore per le tue esigenze e i dati disponibili.

#### Due fasi della formazione LLM

La formazione su modello linguistico di grandi dimensioni consiste in due fasi principali: pre-formazione e post-formazione. Durante la formazione preliminare, il modello elabora i token di testo non elaborato e li ottimizza per la previsione del token successivo. Questo processo crea un completatore di modelli che assorbe la sintassi, la semantica, i fatti e gli schemi di ragionamento dal web e dal testo curato. Tuttavia, il modello pre-addestrato non comprende le istruzioni, gli obiettivi dell'utente o il comportamento appropriato al contesto. Continua il testo in qualsiasi stile si adatti alla distribuzione della formazione. Un modello già addestrato si completa automaticamente anziché seguire le istruzioni, produce una formattazione incoerente e può rispecchiare pregiudizi indesiderati o contenuti non sicuri presenti nei dati di addestramento. La formazione preliminare rafforza la competenza generale, non l'utilità delle attività.

Dopo l'allenamento, il Pattern Completer si trasforma in un utile assistente. Si eseguono diversi cicli di Supervised Fine-Tuning (SFT) per insegnare al modello a seguire le istruzioni, aderire a schemi e politiche, chiamare strumenti e produrre risultati affidabili imitando dimostrazioni di alta qualità. Questo allineamento insegna al modello a rispondere alle istruzioni come attività anziché come testo per continuare. Si applica quindi il Reinforcement Fine-Tuning (RFT) per ottimizzare il comportamento utilizzando feedback misurabili (ad esempio verificatori o altro), bilanciando compromessi come la precisione rispetto alla brevità, la sicurezza rispetto alla copertura o il LLM-as-a-judge ragionamento in più fasi in base ai vincoli. In pratica, si alternano SFT e RFT in cicli per modellare il modello pre-addestrato in un sistema affidabile e allineato alle politiche che esegue attività complesse in modo coerente.

### Scegliete il giusto approccio di personalizzazione

In questa sezione tratteremo le strategie di personalizzazione post-formazione: RFT e SFT.

## Ottimizzazione precisa dei rinforzi (RFT)

La messa a punto del rinforzo migliora le prestazioni del modello attraverso segnali di feedback (punteggi misurabili o premi che indicano la qualità della risposta) anziché la supervisione diretta con risposte esatte e corrette. A differenza della tradizionale ottimizzazione supervisionata che apprende dalle coppie di input-output, RFT utilizza le funzioni di ricompensa per valutare le risposte del modello e ottimizza iterativamente il modello per massimizzare tali ricompense. Questo approccio è ideale per le attività in cui è difficile definire l'output esatto e corretto, ma è possibile misurare in modo affidabile la qualità della risposta. RFT consente ai modelli di apprendere comportamenti e preferenze complessi attraverso prove e feedback, il che lo rende ideale per applicazioni che richiedono un processo decisionale articolato, una risoluzione creativa dei problemi o il rispetto di criteri di qualità specifici che è possibile valutare programmaticamente. Ad esempio, rispondere a domande legali complesse è un caso d'uso ideale per RFT perché si desidera insegnare al modello come ragionare meglio per rispondere alle domande in modo più accurato.

### Come funziona

Nella messa a punto dei rinforzi, si parte da una linea di base basata sulle istruzioni e si tratta ogni richiesta come un piccolo torneo. In base a un determinato contributo, si campionano alcune risposte dei candidati tratte dal modello, si assegna un punteggio a ciascuna di esse con la funzione di ricompensa, quindi le si classifica all'interno di quel gruppo. La fase di aggiornamento spinge il modello a rendere più propensi i candidati con punteggi più alti la prossima volta e meno quelli con punteggi più bassi, mentre un stay-close-to-baseline vincolo impedisce che il comportamento diventi prolioso o sfruttatore. Ripeti questo ciclo su molte richieste, aggiornando i casi più complessi, rendendo più rigorosi i verificatori o giudicando le rubriche quando vedi degli exploit e monitorando continuamente le metriche relative alle attività.

### Quando usare RFT

Le attività che traggono i maggiori vantaggi da RFT hanno diverse caratteristiche in comune. Offrono segnali di successo misurabili anche quando è difficile specificare un singolo output corretto. Ammettono crediti parziali o una qualità graduata, in modo da poter classificare le risposte migliori rispetto a quelle peggiori in un prompt o utilizzando una funzione di ricompensa. Esse implicano molteplici obiettivi che devono essere bilanciati (ad esempio precisione e brevità, chiarezza, sicurezza o costi). Richiedono il rispetto di vincoli espliciti che è possibile verificare a livello di codice. Operano in ambienti mediati da strumenti o basati sull'ambiente in cui i risultati sono osservabili (successo o fallimento, latenza, utilizzo delle risorse). Si verificano in regimi in cui la raccolta di obiettivi prioritari è costosa, ma il feedback automatizzato o basato sulle rubriche è abbondante. RFT funziona al meglio quando è possibile trasformare la qualità in uno scalare o in una classifica

affidabile e se si desidera che il modello amplifichi preferenzialmente i comportamenti che ottengono punteggi più elevati senza bisogno di obiettivi etichettati esaustivi.

Prendi in considerazione altri metodi quando:

- Disponete di numerose e affidabili coppie di ingresso/uscita etichettate: utilizzate SFT
- La lacuna principale è la conoscenza o il gergo: utilizzate la generazione aumentata di recupero (RAG)
- Il segnale di ricompensa è rumoroso o inaffidabile e non è possibile correggerlo con rubriche o pedine migliori: stabilizzalo prima di RFT

Quando non usare RFT

Evita l'RFT in queste situazioni:

- È possibile produrre coppie ingresso-uscita etichettate affidabili a basso costo (SFT è più semplice, economico e stabile)
- Il divario è la conoscenza o il gergo piuttosto che il comportamento (usa RAG)
- Il tuo segnale di ricompensa è rumoroso, scarso, facile da usare, costoso o lento da calcolare (correggi prima il valutatore)
- Le prestazioni di base sono prossime allo zero (avviate con SFT prima di ottimizzare le preferenze)
- L'attività ha schemi deterministici, una formattazione rigorosa o un'unica risposta corretta (la SFT o la convalida basata su regole funzionano meglio)
- I budget limitati in termini di latenza o costi non sono in grado di assorbire i costi aggiuntivi di campionamento o esplorazione richiesti da RFT
- I vincoli relativi alla sicurezza o alle politiche non sono specificati in modo preciso e applicabili nella ricompensa

Se riesci a indicare «la risposta giusta», usa SFT. Se hai bisogno di nuove conoscenze, usa RAG. Usa RFT solo dopo avere una base solida e una funzione di ricompensa robusta e veloce. hard-to-exploit

Fine-tuning supervisionato (SFT)

La messa a punto supervisionata addestra l'LLM su un set di dati di coppie input-output etichettate dall'uomo per ogni attività. Fornite esempi di richieste (domande, istruzioni e così via) con le risposte

corrette o desiderate e continuate ad addestrare il modello sulla base di questi esempi. Il modello regola i propri pesi per ridurre al minimo una perdita supervisionata (in genere entropia incrociata tra le previsioni e i token di output target). Questa è la stessa formazione utilizzata nella maggior parte delle attività di apprendimento automatico supervisionate, applicata per specializzare un LLM.

La SFT modifica il comportamento, non la conoscenza. Non insegna al modello nuovi fatti o gerghi che non aveva appreso durante il pre-allenamento. Insegna al modello come rispondere, non cosa sapere. Se hai bisogno di nuove conoscenze di dominio (come la terminologia interna), usa la generazione aumentata di recupero (RAG) per fornire quel contesto al momento dell'inferenza. SFT aggiunge quindi il comportamento desiderato di seguire le istruzioni.

## Come funziona

SFT ottimizza LLM riducendo al minimo la perdita media di entropia incrociata sui token di risposta, trattando i token prompt come contesto e mascherandoli dalla perdita. Il modello interiorizza lo stile, la struttura e le regole decisionali dell'obiettivo, imparando a generare il completamento corretto per ogni prompt. Ad esempio, per classificare i documenti in categorie personalizzate, si ottimizza il modello con istruzioni (il testo del documento) e completamenti etichettati (le etichette delle categorie). Ci si allena su queste coppie finché il modello non restituisce l'etichetta corretta per ogni prompt con alta probabilità.

È possibile eseguire SFT con poche centinaia di esempi e scalare fino a qualche centinaio di migliaia. I campioni SFT devono essere di alta qualità e allineati direttamente al comportamento del modello desiderato.

## Quando usare SFT

Usa SFT quando hai un'attività ben definita con risultati chiari e desiderati. Se potete dichiarare esplicitamente «Dato l'input X, l'output corretto è Y» e raccogliere esempi di tali mappature, la regolazione fine supervisionata è una buona scelta. SFT eccelle in questi scenari:

- Attività di classificazione strutturate o complesse: classificate documenti o contratti interni in molte categorie personalizzate. Con SFT, il modello impara queste categorie specifiche meglio di quanto lo faccia da solo.
- Attività di risposta a domande o di trasformazione con risposte note: perfeziona un modello per rispondere alle domande della knowledge base di un'azienda o converti i dati tra formati in cui ogni input ha una risposta corretta.
- Formattazione e coerenza stilistica: addestrate il modello a rispondere sempre in un determinato formato o tono perfezionando gli esempi del formato o del tono corretti. Ad esempio, la formazione

sulle coppie di risposte rapide che dimostrano la voce di un marchio specifica insegna al modello a generare risultati con quello stile. Il comportamento che segue le istruzioni viene spesso insegnato inizialmente tramite SFT sulla base di esempi curati di buon comportamento degli assistenti.

L'SFT è il modo più diretto per insegnare a un LLM una nuova abilità o un nuovo comportamento quando è possibile specificare quale sia il comportamento giusto. Utilizza la comprensione linguistica esistente del modello e la concentra sul tuo compito. Utilizzate SFT quando volete che il modello faccia una cosa specifica e avete o potete creare un set di dati di esempi.

Utilizzate SFT quando potete assemblare coppie di prompt e response di alta qualità che rispecchiano fedelmente il comportamento desiderato. Si adatta a compiti con obiettivi chiari o formati deterministici come schemi, chiamate a funzioni o strumenti e risposte strutturate in cui l'imitazione è un segnale di allenamento appropriato. L'obiettivo è modellare il comportamento: insegnare al modello a trattare i prompt come attività, seguire le istruzioni, adottare politiche di tono e rifiuto e produrre una formattazione coerente. Pianifica almeno centinaia di dimostrazioni, con la qualità, la coerenza e la deduplicazione dei dati più importanti del volume grezzo. Per un aggiornamento semplice ed economico, utilizza metodi efficienti in termini di parametri come Low-Rank Adaptation per addestrare piccoli adattatori lasciando intatta la maggior parte della spina dorsale.

### Quando non usare SFT

Non utilizzare SFT quando il divario è la conoscenza piuttosto che il comportamento. Non insegna al modello nuovi fatti, gergo o eventi recenti. In questi casi, utilizza la generazione aumentata con recupero per portare conoscenze esterne all'inferenza. Evita l'SFT quando puoi misurare la qualità ma non riesci a etichettare una sola risposta corretta. Usa la messa a punto dei rinforzi con ricompense verificabili oppure una per ottimizzare direttamente tali ricompense. LLM-as-a-judge Se le tue esigenze o i tuoi contenuti cambiano frequentemente, affidati al recupero e all'uso degli strumenti piuttosto che alla riqualificazione del modello.

### Argomenti

- [SDK Nova Forge](#)
- [Formazione per i modelli Amazon Nova](#)
- [Monitoraggio dei progressi tra le iterazioni](#)
- [Valutazione del modello basato sull' SageMaker intelligenza artificiale](#)
- [Addestramento iterativo](#)

# SDK Nova Forge

Nova Forge SDK è un SDK Python completo per personalizzare i modelli Amazon Nova. L'SDK fornisce un'interfaccia unificata per la formazione, la valutazione, il monitoraggio, l'implementazione e l'inferenza dei modelli Amazon Nova su diverse piattaforme, tra cui AI SageMaker e Amazon Bedrock. Che tu stia adattando i modelli ad attività specifiche del dominio o ottimizzando le prestazioni per il tuo caso d'uso, questo SDK offre tutto ciò di cui hai bisogno in un'unica interfaccia unificata.

## Vantaggi

- Un SDK per l'intero ciclo di vita della personalizzazione del modello, dalla preparazione dei dati all'implementazione e al monitoraggio.
- Supporta diversi metodi di formazione, tra cui il pre-training continuo (CPT), la messa a punto supervisionata (SFT), l'ottimizzazione delle preferenze dirette (DPO) e la regolazione fine del rinforzo (RFT), sia a turno singolo che a turno multiplo, con approcci LoRa e full-rank.
- Supporto integrato per SageMaker Training Jobs e Amazon Bedrock, con gestione automatica delle risorse. SageMaker HyperPod
- Non è più necessario cercare le ricette o l'URI del contenitore giusti per le tue tecniche di allenamento.
- Crea le tue ricette di formazione o utilizza le impostazioni predefinite intelligenti dell'SDK con le sostituzioni dei parametri.
- L'SDK convalida la configurazione rispetto alle combinazioni di modelli e istanze supportate e fornisce supporto per la convalida, prevenendo gli errori prima dell'inizio della formazione.
- CloudWatch Il monitoraggio integrato di Amazon ti consente di monitorare i progressi della formazione in tempo reale.
- Integrato MLFlow per tenere traccia degli esperimenti di formazione con server di MLFlow tracciamento SageMaker AI.

## Requisiti

L'SDK richiede almeno Python 3.12.

## Installazione

Per installare questo SDK, segui il comando seguente.

```
pip install amzn-nova-forge
```

## Modelli e tecniche supportati

L'SDK supporta i seguenti modelli e tecniche all'interno della famiglia Amazon Nova:

| Metodo                                           | Modelli supportati                                      |
|--------------------------------------------------|---------------------------------------------------------|
| Formazione preliminare continua                  | <a href="#">Tutti i modelli Nova</a> (solo SMHP)        |
| Ottimizzazione di LoRa supervisionata            | <a href="#">Tutti i modelli Nova</a>                    |
| Fine tuning supervisionato Full Rank             | <a href="#">Tutti i modelli Nova</a> (solo SMHP e SMTJ) |
| Ottimizzazione diretta delle preferenze LoRa     | Modelli Nova 1.0 (solo SMHP e SMTJ)                     |
| Ottimizzazione diretta delle preferenze complete | Modelli Nova 1.0 (solo SMHP e SMTJ)                     |
| Rinforzo: ottimizzazione LoRa                    | Nova Lite 2.0                                           |
| Ottimizzazione dei rinforzi Full Rank            | Nova Lite 2.0 (solo SMHP e SMTJ)                        |
| Rinforzo multigioco: ottimizzazione LoRa         | Nova Lite 2.0 (solo SMHP)                               |
| Rinforzo multigioco, perfezionamento completo    | Nova Lite 2.0 (solo SMHP)                               |

## Nozioni di base

### Argomenti

- [1. Prepara i tuoi dati](#)
- [2. Configura la tua infrastruttura](#)
- [3. Addestramento](#)
- [4. Monitoraggio](#)
- [5. Valuta](#)
- [6. Implementazione](#)



## 1. Prepara i tuoi dati

Carica il tuo set di dati da file locali o da S3 e lascia che sia l'SDK a gestire la trasformazione nel formato corretto per il metodo di allenamento scelto. Oppure, fornisci dati formattati e inizia subito.

```
from amzn_nova_forge.dataset.dataset_loader import JSONLDatasetLoader
from amzn_nova_forge.model.model_enums import Model, TrainingMethod

loader = JSONLDatasetLoader(question="input", answer="output")
loader.load("s3://your-bucket/training-data.jsonl")
loader.transform(method=TrainingMethod.SFT_LORA, model=Model.NOVA_LITE)
```

## 2. Configura la tua infrastruttura

Scegli le tue risorse di elaborazione: l'SDK convalida le configurazioni e garantisce una configurazione ottimale.

```
from amzn_nova_forge.manager.runtime_manager import BedrockRuntimeManager,
 SMTJRuntimeManager, 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 HyperPod
runtime = SMHPRuntimeManager(
 instance_type="ml.p5.48xlarge",
 instance_count=4,
 cluster_name="my-hyperpod-cluster",
 namespace="kubeflow"
)
```

## 3. Addestramento

Inizia l'allenamento con poche righe di codice.

```
from amzn_nova_forge.model import NovaModelCustomizer
```

```
from amzn_nova_forge.model.model_enums import Model, TrainingMethod

customizer = NovaModelCustomizer(
 model=Model.NOVA_LITE_2,
 method=TrainingMethod.SFT_LORA,
 infra=runtime,
 data_s3_path="s3://your-bucket/prepared-data.jsonl"
)

result = customizer.train(job_name="my-training-job")
```

## 4. Monitoraggio

Tieni traccia dei tuoi progressi di allenamento direttamente dall'SDK.

```
from amzn_nova_forge.monitor.log_monitor import CloudWatchLogMonitor

Monitor training logs
customizer.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. Valuta

Valuta le prestazioni del modello con una varietà di [benchmark integrati](#) o progetta valutazioni personalizzate.

```
from amzn_nova_forge.recipe_config.eval_config import EvaluationTask

Evaluate on benchmark tasks
eval_result = customizer.evaluate(
 job_name="model-eval",
 eval_task=EvaluationTask.MMLU,
 model_path=result.model_artifacts.checkpoint_s3_path
)
```

## 6. Implementazione

Implementa il tuo modello personalizzato in produzione con il supporto integrato per Amazon Bedrock o SageMaker

```
from amzn_nova_forge.model.model_enums import DeployPlatform

Bedrock provisioned throughput
deployment = customizer.deploy(
 model_artifact_path=result.model_artifacts.checkpoint_s3_path,
 deploy_platform=DeployPlatform.BEDROCK_PT,
 pt_units=10
)

Bedrock On-Demand
deployment = customizer.deploy(
 model_artifact_path=result.model_artifacts.checkpoint_s3_path,
 deploy_platform=DeployPlatform.BEDROCK_OD,
 pt_units=10
)

Sagemaker Real-time Inference
deployment = customizer.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",
 }
)
```

## Funzionalità chiave

### Creazione immediata di ricette

L'SDK elimina la necessità di cercare le ricette o l'URI del contenitore appropriati per tecniche specifiche.

## Elaborazione intelligente dei dati

L'SDK trasforma automaticamente i dati nel formato corretto per la formazione. Che tu stia lavorando con file JSON, JSONL o CSV, il data loader gestisce la conversione senza problemi. Data Loader supporta testo e dati multimodali (immagini e video).

## Supporto per l'infrastruttura aziendale

L'SDK funziona sia con SageMaker Training Jobs che con la SageMaker HyperPod gestione automatica di:

- Convalida del tipo di istanza
- Convalida della ricetta
- Convalida di set di dati
- Job orchestrazione e monitoraggio

L'SDK supporta anche la personalizzazione serverless di SageMaker Training Jobs e Bedrock.

## Valutazione completa

Valuta i tuoi modelli personalizzati rispetto a [benchmark standard](#), tra cui:

- MMLU (Massive Multitask Language Understanding)
- BBH (Attività di ragionamento avanzato)
- GPQA (domande e risposte a prova di Google per laureati)

Utilizzate le impostazioni predefinite del benchmark o modificatele in base alle vostre esigenze:

- BYOM (Bring Your Own Metric)
- BYOD (Bring Your Own Dataset)

## Distribuzione in produzione

Distribuisci i tuoi modelli su Amazon Bedrock o SageMaker AI con opzioni per:

- Bedrock Provisioned Throughput: capacità dedicata per prestazioni costanti
- Bedrock On-Demand (applicabile solo alla personalizzazione basata su LoRa) - prezzi Pay-per-use
- SageMaker Inferenza AI in tempo reale: capacità dedicata per prestazioni costanti

## Inferenza in batch

Esegui lavori di inferenza su larga scala in modo efficiente:

- Elabora migliaia di richieste in parallelo
- Aggregazione automatica dei risultati
- Elaborazione in batch conveniente

## Nova Forge

Per gli abbonati a Nova Forge, l'SDK supporta ricette per la miscelazione dei dati.

## Ulteriori informazioni

Sei pronto per iniziare a personalizzare i modelli Nova con Nova Forge SDK? Consulta il nostro GitHub repository per guide dettagliate, riferimenti API ed esempi aggiuntivi: <https://github.com/aws/nova-forge-sdk>

## Formazione per i modelli Amazon Nova

La formazione dei modelli Amazon Nova su SageMaker Training Jobs supporta Supervised Fine-Tuning (SFT) e Reinforcement Fine-Tuning (RFT). Ogni tecnica soddisfa esigenze di personalizzazione diverse e può essere applicata a diverse versioni del modello Amazon Nova.

### Argomenti

- [Ottimizza Nova 2.0](#)
- [Reinforcement Fine-Tuning \(RFT\) con modelli Amazon Nova](#)

## Ottimizza Nova 2.0

### Prerequisiti

Prima di avviare un job di addestramento, verifica i seguenti requisiti.

- Bucket Amazon S3 per archiviare i dati di input e output dei job di addestramento. È possibile utilizzare un bucket per entrambi o bucket distinti per ogni tipo di dati. Assicurati che i tuoi bucket siano gli stessi in Regione AWS cui crei tutte le altre risorse per la formazione. Per ulteriori informazioni, consulta [Creating a general purpose bucket](#).

- Un ruolo IAM con autorizzazioni per eseguire un job di addestramento. Assicurati di collegare una policy IAM con `AmazonSageMakerFullAccess`. Per ulteriori informazioni, consulta [Come utilizzare i ruoli di esecuzione dell' SageMaker IA](#).
- Ricette base di Amazon Nova; consulta [???](#).

## Che cos'è SFT?

Il Supervised Fine-Tuning (SFT) addestra un modello linguistico utilizzando coppie di input-output etichettate. Il modello apprende da esempi dimostrativi costituiti da suggerimenti e risposte, perfezionando le proprie capacità per allinearsi a attività, istruzioni o comportamenti desiderati specifici.

## Preparazione dei dati

### Panoramica di

I dati SFT di Nova 2.0 utilizzano lo stesso formato API Converse di Nova 1.0, con l'aggiunta di campi di contenuto opzionali di ragionamento. Per le specifiche complete del formato, consulta:

- Contenuto del ragionamento: [ReasoningContentBlock](#)
- [Schema dell'API Converse: API Converse](#)
- [Vincoli del set di dati: vincoli del set di dati](#)

## Funzionalità supportate

- Tipi di input: testo, immagine o video nei blocchi di contenuti utente
- Contenuti dell'assistente: risposte di solo testo e contenuti di ragionamento
- Composizione del set di dati: deve essere omogenea. Scegli una delle seguenti opzioni:
  - Turni di solo testo
  - Testo + giri di immagini
  - Svoltare testo e video (supporta la comprensione dei documenti)

### Important

Non è possibile combinare immagini e video all'interno dello stesso set di dati o in turni diversi.

## Limitazioni attuali

- Contenuto di ragionamento multimodale: sebbene il formato Converse supporti contenuti di ragionamento basati su immagini, Nova 2.0 SFT supporta solo contenuti di ragionamento basati su testo nel campo ReasoningText.
- Set di convalida: non è possibile fornire un set di dati di convalida per SFT con Nova 2.0. Se fornite un set di dati di convalida, questo viene ignorato durante l'addestramento. Questa limitazione si applica sia agli invii di lavoro basati sull'interfaccia utente che a quelli programmatici.

## Formati multimediali supportati

- Immagini: PNG, JPEG, GIF
- Video: MOV, MKV, MP4

## Esempi di formati di dati

### 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"
 }
]
}
]
}

```

## Chiamata di strumenti

Nova 2.0 SFT supporta modelli di addestramento sui modelli di chiamata degli strumenti, consentendo al modello di apprendere quando e come richiamare strumenti o funzioni esterni.

## Formato dati per la chiamata degli strumenti

I dati di addestramento sulla chiamata agli strumenti includono una `toolConfig` sezione che definisce gli strumenti disponibili, oltre a turni di conversazione che mostrano i modelli di utilizzo degli strumenti.

## Esempio di input

```

{
 "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?"
 }
]
}
]
```

## Requisiti di chiamata degli strumenti

Quando create dati di addestramento per le chiamate agli strumenti, attenetevi ai seguenti requisiti:

| Requisito                | Description                                                                                                                                                                       |
|--------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| ToolUse collocamento     | ToolUse deve apparire solo nei turni degli assistenti                                                                                                                             |
| ToolResult collocamento  | ToolResult deve apparire solo nei turni degli utenti                                                                                                                              |
| ToolResult formato       | ToolResult deve essere solo testo o JSON. Altre modalità non sono supportate per i modelli Nova                                                                                   |
| Formato InputSchema      | L'inputSchema all'interno di ToolSpec deve essere un oggetto Schema JSON valido                                                                                                   |
| toolUseId corrispondente | Ciascuno ToolResult deve fare riferimento a un assistente valido toolUseId di un precedente ToolUse, e ognuno deve toolUseId essere usato esattamente una volta per conversazione |

## Note importanti

- Assicurati che le definizioni degli strumenti siano coerenti in tutti gli esempi di formazione

- Il modello apprende i modelli di invocazione degli strumenti dalle dimostrazioni fornite
- Includi diversi esempi di quando usare ogni strumento e quando non usare gli strumenti

## Comprensione dei documenti

Nova 2.0 SFT supporta la formazione sulle attività basate su documenti, consentendo al modello di imparare ad analizzare e rispondere alle domande sui documenti PDF.

## Formato dei dati per la comprensione dei documenti

I dati di formazione sulla comprensione dei documenti includono riferimenti ai documenti nei blocchi di contenuti utente, mentre il modello impara a estrarre e ragionare sul contenuto del documento.

## Esempio di input

```
{
 {
 "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?"
 }
]
}
}
```

## Limiti alla comprensione dei documenti

| Limitazione                      | Informazioni                                                                                                               |
|----------------------------------|----------------------------------------------------------------------------------------------------------------------------|
| Formato supportato               | Solo file PDF                                                                                                              |
| Dimensione massima del documento | 10 MB                                                                                                                      |
| Miscelazione delle modalità      | Un campione può contenere documenti e testo, ma non può contenere documenti mescolati con altre modalità (immagini, video) |

## Le migliori pratiche per la comprensione dei documenti

- Assicurati che i documenti siano formattati in modo chiaro e che il testo sia estraibile
- Fornisci diversi esempi che coprono diversi tipi di documenti e formati di domande
- Includi contenuti di ragionamento per aiutare il modello ad apprendere i modelli di analisi dei documenti



## Comprensione dei video

Nova 2.0 SFT supporta la formazione sulle attività basate su video, consentendo al modello di imparare ad analizzare e rispondere alle domande sui contenuti video.

### Formato dei dati per la comprensione dei video

I dati di formazione sulla comprensione dei video includono riferimenti video nei blocchi di contenuti utente, mentre il modello impara a estrarre informazioni e ragionare sui contenuti video.

### Esempio di input

```
{
 "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?"
}
]
}
]
```

### Limitazioni sulla comprensione dei video

| Limitazione                  | Informazioni                                                                                                 |
|------------------------------|--------------------------------------------------------------------------------------------------------------|
| Dimensione massima del video | 50 MB                                                                                                        |
| Durata massima del video     | 15 minuti                                                                                                    |
| Video per campione           | È consentito un solo video per campione. Non sono supportati più video nello stesso campione                 |
| Miscelazione delle modalità  | Un campione può contenere video e testo, ma non può combinare video con altre modalità (immagini, documenti) |

### Formati video supportati

- MOV
- MKV
- MP4

## Le migliori pratiche per la comprensione dei video

- Mantieni i video concisi e incentrati sui contenuti pertinenti alla tua attività
- Assicurati che la qualità video sia sufficiente per consentire al modello di estrarre informazioni significative
- Fornisci domande chiare che facciano riferimento ad aspetti specifici dei contenuti video
- Includi diversi esempi che coprono diversi tipi di video e formati di domande

## Modalità di ragionamento e non ragionamento

### Comprensione del contenuto del ragionamento

Il contenuto del ragionamento (chiamato anche chain-of-thought) cattura le fasi di pensiero intermedie del modello prima di generare una risposta finale. A assistant sua volta, usa il `reasoningContent` campo per includere queste tracce di ragionamento.

### Come viene calcolata la perdita

- Con contenuto di ragionamento: la perdita di formazione include sia i token di ragionamento che i token di output finale
- Senza contenuti di ragionamento: la perdita di formazione viene calcolata solo sui token di output finali

Puoi includere più turni di assistente `reasoningContent` in conversazioni a turni multipli.

### Linee guida per la formattazione

- Usa testo semplice per ragionare i contenuti
- Evita i tag di markup come `<thinking>` e `</thinking>` a meno che non siano specificamente richiesti dalla tua attività
- Assicurati che il contenuto del ragionamento sia chiaro e pertinente al processo di risoluzione dei problemi

### Quando abilitare la modalità di ragionamento

Imposta `reasoning_enabled: true` nella configurazione di allenamento quando:

- I tuoi dati di allenamento contengono token di ragionamento
- Volete che il modello generi token di pensiero prima di produrre gli output finali
- È necessario migliorare le prestazioni in attività di ragionamento complesse

È consentito addestrare Nova su un set di dati non ragionevoli con `reasoning_enabled = true`. Tuttavia, così facendo il modello potrebbe perdere le sue capacità di ragionamento, poiché Nova impara principalmente a generare le risposte presentate nei dati senza applicare il ragionamento. Se vuoi addestrare Nova su un set di dati non ragionante ma ti aspetti comunque un ragionamento durante l'inferenza, puoi disabilitare il ragionamento durante l'addestramento () ma abilitarlo per l'inferenza. `reasoning_enabled = false`. Sebbene questo approccio consenta di utilizzare il ragionamento in fase di inferenza, non garantisce prestazioni migliori rispetto all'inferenza senza ragionamento. In generale, abilita il ragionamento sia per l'addestramento che per l'inferenza quando si utilizzano set di dati di ragionamento e disabilitalo per entrambi quando si utilizzano set di dati non di ragionamento.

Imposta quando: `reasoning_enabled: false`

- I tuoi dati di allenamento non dispongono di token di ragionamento
- Ti stai allenando su attività semplici che non traggono vantaggio da passaggi di ragionamento espliciti
- Vuoi ottimizzare la velocità e ridurre l'utilizzo dei token

## Generazione di dati di ragionamento

Se il tuo set di dati non contiene tracce di ragionamento, puoi crearle utilizzando un modello in grado di ragionare come Nova Premier. Fornisci le tue coppie di input-output al modello e acquisisci il relativo processo di ragionamento per creare un set di dati basato sul ragionamento.

## Utilizzo di token di ragionamento per la formazione

Quando si allena con la modalità di ragionamento abilitata, il modello impara a separare il ragionamento interno dalla risposta finale. Il processo di formazione:

- Organizza i dati in tre parti: input, ragionamento e risposta
- Ottimizza l'utilizzo degli standard di previsione del token successivo (perdita derivante sia dai token di ragionamento che da quelli di risposta)
- Incoraggia il modello a ragionare internamente prima di generare risposte

## Contenuti di ragionamento efficaci

I contenuti di ragionamento di alta qualità dovrebbero includere:

- Pensieri e analisi intermedi
- Deduzioni logiche e fasi di inferenza
- Step-by-step approcci per la risoluzione dei problemi
- Connessioni esplicite tra fasi e conclusioni

Questo aiuta il modello a sviluppare la capacità di «pensare prima di rispondere».

## Linee guida per la preparazione dei dataset

### Dimensioni e qualità

- Dimensione consigliata: 2.000-10.000 campioni
- Campioni minimi: 200
- Priorità: qualità rispetto alla quantità. Assicurati che gli esempi siano accurati e ben annotati
- Allineamento delle applicazioni: il set di dati deve rispecchiare fedelmente i casi d'uso in produzione

### Diversità

Includi diversi esempi che:

- Copre l'intera gamma di input previsti
- Rappresenta diversi livelli di difficoltà
- Includi casi limite e varianti
- Evita l'eccessivo adattamento a modelli ristretti

### Formattazione dell'output

Specificate chiaramente il formato di output desiderato nelle risposte dell'assistente:

- Strutture JSON
- Tabelle

- Formato CSV
- Formati personalizzati specifici per la tua applicazione

## Conversazioni a più turni

Per set di dati a turni multipli, ricorda:

- La perdita viene calcolata solo in base ai turni degli assistenti, non ai turni degli utenti
- Ogni risposta dell'assistente deve essere formattata correttamente
- Mantieni la coerenza nei turni di conversazione

## Lista di controllo della qualità

- Dimensioni sufficienti del set di dati (campioni da 2K-10K)
- Diversi esempi che coprono tutti i casi d'uso
- Formattazione di output chiara e coerente
- Etichette e annotazioni accurate
- Rappresentante degli scenari di produzione
- Liberi da contraddizioni o ambiguità

## Caricamento dei dati

I set di dati devono essere caricati in un bucket accessibile dai corsi di formazione. SageMaker [Per informazioni sull'impostazione delle autorizzazioni corrette, consulta Prerequisiti.](#)

## Avvio di un lavoro di formazione

### Selezione degli iperparametri e aggiornamento della ricetta

La configurazione di Nova 2.0 è in gran parte la stessa di Nova 1.0. Una volta che i dati di input sono stati caricati su S3, usa la ricetta contenuta nella cartella [SageMaker HyperPod Recipes](#) nella cartella Fine tuning. Per Nova 2.0, di seguito sono riportati alcuni degli iperparametri chiave che è possibile aggiornare in base al caso d'uso. Di seguito è riportato un esempio della ricetta Nova 2.0 SFT PEFT. Per l'URI dell'immagine del contenitore, utilizzare `708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-TJ-SFT-V2-latest` per eseguire un processo di ottimizzazione SFT.

Utilizza la versione 2.254.1 di SageMaker AI PySDK per una stretta compatibilità con Nova Training. L'aggiornamento dell'SDK alla versione v3.0 comporterà modifiche sostanziali. Il supporto per la versione 3 di SageMaker AI PySDK sarà presto disponibile.

### Esempio di input

```
!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

```

La ricetta contiene anche in gran parte gli stessi iperparametri di Nova 1.0. Gli iperparametri più importanti sono:

- **max\_steps**— Il numero di passaggi per i quali si desidera eseguire il processo. In genere, per un'epoca (una analisi dell'intero set di dati), il numero di passaggi = numero di campioni di dati/ dimensione globale del batch. Maggiore è il numero di passaggi e minore è la dimensione del batch globale, maggiore sarà il tempo necessario per l'esecuzione del processo.
- **reasoning\_enabled**— Controlla la modalità di ragionamento per il set di dati. Opzioni:
  - **true**: abilita la modalità di ragionamento (equivalente al ragionamento elevato)
  - **false**: disabilita la modalità di ragionamento

Nota: per SFT, non esiste un controllo granulare sui livelli di sforzo di ragionamento.

L'impostazione `reasoning_enabled: true` consente la piena capacità di ragionamento.

- **peft.peft\_scheme**— L'impostazione su «lora» consente la regolazione fine basata su PEFT. L'impostazione su null (senza virgolette) abilita la regolazione fine Full-Rank.

Inizia il lavoro di formazione

```

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

Il passaggio di un set di dati di convalida non è supportato per la regolazione fine supervisionata di Nova 2.0.

Per dare il via al lavoro:

- Aggiorna la ricetta con i percorsi e gli iperparametri del set di dati
- Esegui le celle specificate nel notebook per inviare il lavoro di formazione

Il notebook gestisce l'invio dei lavori e ne monitora lo stato.

## Reinforcement Fine-Tuning (RFT) con modelli Amazon Nova

Panoramica di

Che cos'è RFT?

Il Reinforcement Fine-Tuning (RFT) migliora le prestazioni del modello addestrandosi sui segnali di feedback (punteggi misurabili o premi che indicano le prestazioni del modello) anziché sulle risposte esatte e corrette. A differenza della messa a punto supervisionata che apprende dalle coppie input-output, RFT utilizza le funzioni di ricompensa per valutare le risposte del modello e ottimizza iterativamente il modello per massimizzare tali ricompense. Questo approccio eccelle quando è difficile definire l'output esatto e corretto, ma è possibile misurare in modo affidabile la qualità della risposta.

Quando usare RFT

Usa RFT quando puoi definire criteri di successo chiari e misurabili ma hai difficoltà a fornire risultati esatti e corretti per la formazione. È ideale per:

- Attività in cui la qualità è soggettiva o multiforme (scrittura creativa, ottimizzazione del codice, ragionamento complesso)
- Scenari con più soluzioni valide in cui alcune sono chiaramente migliori di altre
- Applicazioni che richiedono miglioramento iterativo, personalizzazione o rispetto di regole aziendali complesse
- Casi in cui la raccolta di esempi etichettati di alta qualità è costosa o poco pratica

## I migliori casi d'uso

RFT eccelle nei settori in cui la qualità dell'output può essere misurata oggettivamente, ma le risposte ottimali sono difficili da definire in anticipo:

- Risoluzione di problemi matematici e generazione di codice
- Ragionamento scientifico e analisi strutturata dei dati
- Compiti che richiedono step-by-step ragionamento o risoluzione di problemi a più turni
- Applicazioni che bilanciano più obiettivi (precisione, efficienza, stile)
- Scenari in cui il successo può essere verificato a livello di codice attraverso i risultati di esecuzione o le metriche delle prestazioni

## Modelli supportati

### Nova Lite 2.0

## Panoramica del formato dei dati

[I dati di addestramento RFT devono seguire il formato OpenAI Reinforcement Fine-Tuning.](#) Ogni esempio di addestramento è un oggetto JSON contenente:

- Un `messages` array con turni di conversazione, utilizzo e ruoli `system` `user`
- Un `reference_answer` campo contenente l'output previsto o i criteri di valutazione per il calcolo della ricompensa

## Limitazioni attuali

- Solo testo

## Esempi di formati di dati

Ogni esempio deve essere su una sola riga del file JSONL, con un oggetto JSON per riga.

### 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
 }
}

```

Il `reference_answer` campo contiene l'output previsto o i criteri di valutazione utilizzati dalla funzione di ricompensa per assegnare un punteggio alla risposta del modello. Non si limita agli output strutturati, ma può contenere qualsiasi formato che aiuti la funzione di ricompensa a valutare la qualità.

Consigli sulle dimensioni dei set di dati

Punto di partenza

- Minimo 100 esempi di formazione

- Minimo 100 esempi di valutazione

## Approccio basato sulla valutazione

Prima di investire nella formazione RFT su larga scala, valuta le prestazioni di base del tuo modello:

- Prestazioni elevate (ricompensa superiore al 95%): la tecnologia RFT potrebbe non essere necessaria: il modello offre già buone prestazioni
- Prestazioni molto scarse (ricompensa dello 0%): passate innanzitutto a SFT per stabilire le funzionalità di base
- Prestazioni moderate: la tecnologia RFT è probabilmente appropriata

Iniziare con un set di dati di piccole dimensioni consente di:

- Verifica che la tua funzione di ricompensa sia priva di bug
- Conferma che RFT è l'approccio giusto per il tuo caso d'uso
- Identifica e risolvi tempestivamente i problemi
- Testa il flusso di lavoro prima di ampliarlo

Una volta convalidato, puoi espanderlo a set di dati più grandi per migliorare ulteriormente le prestazioni.

## Caratteristiche dei dati di allenamento efficaci

### Chiarezza e coerenza

I buoni esempi RFT richiedono dati di input chiari e inequivocabili che consentano un calcolo accurato della ricompensa tra i diversi output del modello. Evita il rumore nei tuoi dati, tra cui:

- Formattazione non coerente
- Etichette o istruzioni contraddittorie
- Istruzioni ambigue
- Risposte di riferimento contrastanti

Qualsiasi ambiguità indurrà in errore il processo di formazione e indurrà il modello ad apprendere comportamenti non intenzionali.

## Diversità

Il tuo set di dati dovrebbe catturare l'intera diversità dei casi d'uso di produzione per garantire solide prestazioni nel mondo reale. Include:

- Diversi formati di input e custodie periferiche
- Mappa i modelli effettivi di utilizzo della produzione sulla base dei log e delle analisi degli utenti
- Esamina diversi tipi di utenti, aree geografiche e variazioni stagionali
- Includi livelli di difficoltà da problemi semplici a complessi

## Considerazioni sulla funzione di ricompensa

Progetta la tua funzione di ricompensa per un allenamento efficiente:

- Esegui in pochi secondi (non in minuti)
- Parallelizza efficacemente con Lambda
- Restituisci punteggi coerenti e affidabili
- Gestisci con eleganza diversi tipi di output del modello

Le funzioni di ricompensa veloci e scalabili consentono un'iterazione rapida e una sperimentazione conveniente.

## Proprietà aggiuntive

Il formato di dati RFT supporta campi personalizzati oltre ai requisiti di base dello schema (e). `messages.reference_answer` Questa flessibilità consente di aggiungere tutti i dati aggiuntivi necessari alla funzione di ricompensa per una corretta valutazione.

### Note

Non è necessario configurarlo nella ricetta: il formato dei dati supporta intrinsecamente campi aggiuntivi. Basta includerli nei dati di allenamento JSON e verranno passati alla funzione di ricompensa sul campo. `metadata`

## Proprietà aggiuntive comuni

Campi di metadati di esempio:

- `task_id`— Identificatore univoco per il tracciamento
- `difficulty_level`— Indicatore di complessità del problema
- `domain`— Area o categoria tematica
- `expected_reasoning_steps`— Numero di passaggi della soluzione

### Esempio con proprietà aggiuntive

```
{
 "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
}
```

Questi campi aggiuntivi vengono passati alla funzione di ricompensa durante la valutazione, abilitando una sofisticata logica di punteggio personalizzata in base al caso d'uso specifico.

### Configurazione di addestramento

#### Ricetta di esempio

```
Note:
This recipe can run on p5.48xlarge and p5en.48xlarge instance types.
run:
 name: "my-rft-run" # Unique run name (appears in logs/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;
replicas: 4
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 GRPO Training specific configs
training_config:
 max_length: 8192 # Context window (tokens) for inputs
+prompt;
 global_batch_size: 16 # Total samples per optimizer step
 across all replicas (16/32/64/128/256).
 reasoning_effort: high # Enables reasoning mode high / low /
or null for non-reasoning

 rollout: # How responses are generated for GRPO/
advantage calc.
 advantage_strategy:
 number_generation: 2 # N samples per prompt to estimate
advantages (variance vs 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;
 top_k: 1 # Sample only from top-K logits
 rewards:
 preset_reward_function: null # Usage of preset reward functions
[exact_match]
 api_endpoint:
 lambda_arn: arn:aws:lambda:<region>:<account-id>:function:<function-name>
 lambda_concurrency_limit: 12 # Max concurrent Lambda invocations
(throughput vs. throttling).

 trainer:
 max_steps: 2 # Steps to train for. One Step =
global_batch_size
 save_steps: 5
 test_steps: 1

```

```

RL parameters
ent_coeff: 0.0 # A bonus added to the policy loss that
rewards higher-output entropy.
kl_loss_coef: 0.001 # Weight on the KL penalty between the
actor (trainable policy) and a frozen reference model

optim_config: # Optimizer settings
 lr: 5e-5 # Learning rate
 weight_decay: 0.0 # L2 regularization strength (0.0-1.0)
 adam_beta1: 0.9
 adam_beta2: 0.95

peft: # Parameter-efficient fine-tuning (LoRA)
 peft_scheme: "lora" # Enable LoRA for PEFT
 lora_tuning:
 alpha: 32
 lora_plus_lr_ratio: 64.0 # LoRA+ learning rate scaling factor (0.0-
100.0)

```

## Formazione RFT utilizzando LLM come giudice

### Panoramica di

I modelli linguistici di grandi dimensioni (LLMs) vengono sempre più utilizzati come giudici nei flussi di lavoro di reinforcement fine-tuning (RFT), che forniscono segnali di ricompensa automatici che guidano l'ottimizzazione dei modelli. In questo approccio, un LLM valuta i risultati del modello in base a criteri specifici, che si tratti di valutare la correttezza, la qualità, l'aderenza allo stile o l'equivalenza semantica, e assegna premi che guidano il processo di reinforcement learning.

Ciò è particolarmente utile per le attività in cui le funzioni di ricompensa tradizionali sono difficili da definire programmaticamente, come determinare se rappresentazioni diverse (come «1/3», «0,333» e «un terzo») sono semanticamente equivalenti o valutare qualità sfumate come coerenza e pertinenza. Utilizzando i giudici basati su LLM come funzioni di ricompensa, puoi scalare RFT su domini complessi senza richiedere ampie annotazioni umane, consentendo una rapida iterazione e il miglioramento continuo dei tuoi modelli in diversi casi d'uso oltre ai tradizionali problemi di allineamento.

### Selezione della modalità di ragionamento

### Modalità disponibili

- none — Nessun ragionamento (ometti il campo `reasoning_effort`)
- low — Sovraccarico minimo di ragionamento
- high — Capacità massima di ragionamento (impostazione predefinita quando è specificato `reasoning_effort`)

#### Note

Non esiste un'opzione media per RFT. Se il campo `reasoning_effort` non è presente nella configurazione, il ragionamento è disabilitato. Quando il ragionamento è abilitato, è necessario `max_new_tokens` impostarlo su 32768 per accogliere output di ragionamento estesi.

Quando usare ciascuna modalità

Usa un ragionamento elevato per:

- Compiti analitici complessi
- Risoluzione di problemi matematici
- Deduzione logica in più fasi
- Attività in cui il step-by-step pensiero aggiunge valore

Usa none (ometti `reasoning_effort`) o low reasoning per:

- Semplici domande fattuali
- Classificazioni dirette
- Ottimizzazione della velocità e dei costi
- Risposta semplice alle domande

Compromessi in termini di costi e prestazioni

Aumentano le modalità di ragionamento più elevate:

- Tempi e costi della formazione
- Latenza e costi dell'inferenza
- Capacità di modellazione per attività di ragionamento complesse

## Convalida del tuo giudice LLM

Prima di implementarne uno LLM-as-a-judge in produzione, verifica che le valutazioni del modello arbitrale siano in linea con il giudizio umano. Questa operazione prevede:

- Misurazione dei tassi di concordanza tra il giudice del LLM e i valutatori umani su campioni rappresentativi del vostro compito
- Garantire che l'accordo del LLM con gli esseri umani soddisfi o superi i tassi di accordo interumani
- Identificazione di potenziali pregiudizi nel modello del giudice
- Acquisire la fiducia che il segnale di ricompensa guidi il modello nella direzione prevista

Questa fase di convalida aiuta a garantire che il processo di valutazione automatizzato produca modelli che soddisfino i criteri di qualità della produzione.

## Configurazione Lambda per LLM judge

L'utilizzo di un LLM come giudice è un'estensione dell'utilizzo delle funzioni Lambda per il Reinforcement Learning with Verifiable Rewards (RLVR). All'interno della funzione Lambda, effettui una chiamata a uno dei modelli ospitati in Amazon Bedrock.

Requisiti di configurazione importanti:

| Configurazione                 | Requisito            | Informazioni                                                                                                                                                                              |
|--------------------------------|----------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Produttività di Amazon Bedrock | Quota sufficiente    | Assicurati che la tua quota di throughput per il modello Amazon Bedrock utilizzato sia sufficiente per il tuo carico di lavoro di formazione                                              |
| Timeout Lambda                 | Timeout prolungato   | Configura il timeout della funzione Lambda fino a un massimo di 15 minuti. L'impostazione predefinita è di 3 secondi, il che non è sufficiente per le risposte del modello Amazon Bedrock |
| Simultaneità Lambda            | Maggiore concorrenza | La Lambda viene richiamata in parallelo durante l'allenamento. Aumenta la concorrenza per massimizzare la velocità effettiva disponibile                                                  |

| Configurazione               | Requisito                     | Informazioni                                                   |
|------------------------------|-------------------------------|----------------------------------------------------------------|
| Configurazione della ricetta | Abbina le impostazioni Lambda | Il limite di concorrenza deve essere configurato nella ricetta |

## Creazione ed esecuzione di lavori

### Avvio di un lavoro di formazione

Usa il modello di taccuino per i lavori di SageMaker formazione: <https://docs.aws.amazon.com/sagemaker/latest/dg/nova-fine-tuning-training-job.html#nova-model-training-jobs-notebook>

### Requisiti dell'ist

Il contenitore supporta sia la formazione Full-Rank che quella LoRa:

- Formazione LoRa: istanze 2/4/6/8 × p5.48xlarge o p5en.48xlarge
- Formazione completa - istanze 2/4/6/8 × p5.48xlarge (obbligatorio)

### Monitoraggio della formazione

I registri di formazione includono metriche complete per ogni fase. Categorie metriche chiave:

#### Metriche sulle ricompense

- `critic/rewards/mean`, `critic/rewards/max`, `critic/rewards/min` — Distribuzione dei premi
- `val-score/rewards/mean@1` — Premi di convalida

#### Comportamento del modello

- `actor/entropy` — Variazione delle politiche (maggiore = più esplorativa)

#### Formazione e salute

- `actor/pg_loss` — Perdita del gradiente politico
- `actor/pg_clipfrac` — Frequenza degli aggiornamenti interrotti

- `actor/grad_norm`— Magnitudine del gradiente

### Caratteristiche di risposta

- `prompt_length/mean`, `prompt_length/max`, `prompt_length/min` — Statistiche sui token di input
- `response_length/mean`, `response_length/max`, `response_length/min` — Statistiche sui token di output
- `response/aborted_ratio`— Frequenza di generazione incompleta (0 = tutto completato)

### Prestazioni

- `perf/throughput`— Produttività della formazione
- `perf/time_per_step`— Tempo per fase di allenamento
- `timing_per_token_ms/*`— Tempi di elaborazione per token

### Utilizzo delle risorse

- `perf/max_memory_allocated_gb`, `perf/max_memory_reserved_gb` — Memoria GPU
- `perf/cpu_memory_used_gb`— memoria CPU

### Utilizzo di modelli ottimizzati

Al termine dell'addestramento, il checkpoint finale del modello viene salvato nella posizione di output specificata. Il percorso del checkpoint è disponibile in:

- Registri di allenamento
- `manifest.json` file nella posizione di output di Amazon S3 (definita `output_s3_uri` nel notebook)

### Limitazioni e best practice

#### Limitazioni

- Timeout Lambda: le funzioni Reward devono essere completate entro 15 minuti (previene processi inutili e gestisce i costi)

- Solo turno singolo: le conversazioni a turni multipli non sono supportate
- Requisiti in materia di dati: richiede una diversità sufficiente; ha difficoltà con ricompense scarse (esempi positivi inferiori al 5%)
- Costo computazionale: più costoso della messa a punto supervisionata
- Nessun dato multimodale: è supportato solo il tipo di dati di testo

## Best practice

### Inizia in piccolo

- Inizia con 100-200 esempi
- Convalida la correttezza della funzione di ricompensa
- Scala gradualmente in base ai risultati

### Valutazione pre-allenamento

- Verifica le prestazioni del modello di base prima di RFT
- Se i premi sono costantemente pari allo 0%, utilizza prima SFT per stabilire le funzionalità di base
- Se i premi sono superiori al 95%, la RFT potrebbe non essere necessaria

### Monitora la formazione

- Tieni traccia dei punteggi e della distribuzione medi dei premi
- Fai attenzione all'overfitting (i premi di formazione aumentano mentre i premi di convalida diminuiscono)
- Cerca i modelli riguardanti:
  - I premi si stabilizzano al di sotto di 0,15
  - Aumento della varianza delle ricompense nel tempo
  - Diminuzione delle prestazioni di convalida

### Ottimizza le funzioni di ricompensa

- Esegui in pochi secondi (non in minuti)
- Riduci al minimo le chiamate API esterne

- Utilizza algoritmi efficienti
- Implementa una corretta gestione degli errori
- Sfrutta la scalabilità parallela di Lambda

### Strategia di iterazione

Se le ricompense non migliorano:

- Modifica il design della funzione di ricompensa
- Aumenta la diversità dei set di dati
- Aggiungi altri esempi rappresentativi
- Verifica che i segnali di ricompensa siano chiari e coerenti

### Funzionalità avanzate: Nova Forge

Per gli utenti che richiedono funzionalità avanzate oltre ai limiti RFT standard, Nova Forge è disponibile come servizio di abbonamento a pagamento che offre:

- Supporto per conversazioni a turni
- Funzioni di ricompensa con un tempo di esecuzione superiore a 15 minuti
- Algoritmi e opzioni di ottimizzazione aggiuntivi
- Modifiche personalizzate alla ricetta di allenamento
- State-of-the-art Tecniche di intelligenza artificiale

Nova Forge funziona SageMaker HyperPod ed è progettata per supportare i clienti aziendali nella creazione dei propri modelli di frontiera.

### Comandi e suggerimenti utili

È disponibile una raccolta di [script di osservabilità](#) per aiutare a monitorare lo stato e l'avanzamento dei lavori di formazione.

Gli script disponibili sono:

- Attivazione delle notifiche e-mail per gli aggiornamenti sullo stato dei lavori di formazione
- Ottenere stime dei tempi di formazione in base alle configurazioni dei lavori
- Ottenere approssimazioni sulla durata prevista della formazione per i lavori in corso



## Installazione

### Note

Assicurati di aggiornare AWS le tue credenziali prima di utilizzare uno dei seguenti script.

```
pip install boto3
git clone https://github.com/aws-samples/amazon-nova-samples.git
cd amazon-nova-samples/customization/SageMakerUilts/SageMakerJobsMonitoring/
```

## Utilizzo di base

```
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
```

Per ulteriori dettagli ed esempi, consulta [questa](#) pagina.



## Monitoraggio dei progressi tra le iterazioni

Puoi tenere traccia delle metriche tramite MLflow.

### Nova Customization: MLFlow configurazione per SageMaker HyperPod

Per consentire all' SageMaker HyperPod ambiente di emettere le metriche MLFlow, è necessario eseguire alcune impostazioni aggiuntive.

1. Apri Amazon SageMaker AI
2. Seleziona SageMaker Studio
  - a. Se è già stato creato un profilo, seleziona «Open Studio».
  - b. Se non viene creato alcun profilo, seleziona «Crea un SageMaker dominio» per configurarne uno
3. Seleziona MLFlow. Se non è stata creata alcuna MLFlow app, seleziona «Crea MLFlow app»
4. Fai clic sul copy/paste pulsante o sulla voce di menu «Visualizza dettagli» nell'app ML Flow per ottenere l'ARN. Ne avrai bisogno quando invierai il tuo lavoro di formazione.



5. Sul ruolo di esecuzione del HyperPod cluster, aggiungi la seguente politica. Ciò consentirà al HyperPod cluster di chiamare l' MLFlow API per pubblicare le metriche.

```
{
 "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": "*"
 }
]
}

```

Invio di un lavoro tramite la CLI

Specificare 4 nuovi parametri di override, nella riga di comando o nella ricetta yaml.

1. `mlflow_tracking_uri`: L'ARN dell'app MLFlow
2. `mlflow_experiment_name`: Il nome di questa esecuzione dell'esperimento
3. `mlflow_experiment_name`: Il nome dell'esperimento in cui verranno archiviate le metriche MLFlow
4. `mlflow_run_name`: Il nome di questo esperimento

Riga di comando

```

--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"

```

Invio di un lavoro tramite l'interfaccia utente di Studio SageMaker

MLFlow l'integrazione è già integrata nell'esperienza dell'interfaccia utente di SageMaker Studio. Quando invii un lavoro di formazione, indica semplicemente quale istanza MLFlow dell'app utilizzare.

1. In SageMaker Studio, accedi a Modelli > Nova 2.0 Lite > Personalizza > Personalizza con interfaccia utente.
2. Espandi la sezione Configurazione avanzata
3. Seleziona l' MLflow app a cui desideri inviare le metriche di allenamento. Puoi anche impostare il nome dell'esperimento e l'esecuzione dell'esperimento qui.

## Invio di un lavoro tramite AWS AWS CLI

Se utilizzi il AWS AWS CLI, devi creare un' MLflow app e passarla come input alla richiesta API di training job.

```
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)
```

## Crea un' MLflow app

Utilizzo dell'interfaccia utente di Studio: se crei un lavoro di formazione tramite l'interfaccia utente di Studio, viene creata automaticamente MLflow un'app predefinita e selezionata per impostazione predefinita in Opzioni avanzate.

Utilizzo della CLI: se utilizzi la CLI, devi creare un' MLflow app e passarla come input alla richiesta API del lavoro di formazione.

```
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)
```

## Accedi all'app MLflow

Utilizzo della CLI: crea un URL prefirmato per accedere all'interfaccia utente dell' MLflow app:

```
aws sagemaker create-presigned-mlflow-app-url \
 --arn $mlflow_app_arn \
 --region $region \
 --output text
```

Utilizzo dell'interfaccia utente di Studio: l'interfaccia utente di Studio mostra le metriche chiave archiviate MLflow e fornisce un collegamento all'interfaccia utente dell' MLflow app.

## Metriche chiave da monitorare

Monitora queste metriche tra le iterazioni per valutare i miglioramenti e monitorare l'avanzamento del lavoro:

Per SFT

- Curve di perdita in allenamento
- Numero di campioni consumati e tempo di elaborazione dei campioni
- Precisione delle prestazioni su set di test esauriti
- Conformità del formato (ad esempio, velocità di output JSON valida)
- Perplexità sui dati di valutazione specifici del dominio

## Per RFT

- Punteggi medi di ricompensa rispetto agli allenamenti
- Distribuzione dei premi (percentuale di risposte ad alto rendimento)
- Tendenze relative alla validazione e ai premi (attenzione all'overfit)
- Percentuali di successo specifiche delle attività (ad esempio, velocità di esecuzione del codice, precisione dei problemi matematici)

## Ambito generale

- Effettua il benchmark dei delta prestazionali tra le iterazioni
- Punteggi di valutazione umana su campioni rappresentativi
- Metriche di produzione (se implementate in modo iterativo)

## Determinare quando fermarsi

Interrompi l'iterazione quando:

- Livelli prestazionali: la formazione aggiuntiva non migliora più in modo significativo le metriche target
- Il cambio di tecnica aiuta: se una tecnica si stabilizza, prova a cambiarla (ad esempio, SFT → RFT → SFT) per superare i limiti prestazionali
- Metriche obiettivo raggiunte: i tuoi criteri di successo sono soddisfatti
- Regressione rilevata: le nuove iterazioni riducono le prestazioni (vedi le procedure di rollback di seguito)

Per le procedure di valutazione dettagliate, consulta la sezione Valutazione.

## Valutazione del modello basato sull' SageMaker intelligenza artificiale

Lo scopo del processo è valutare le prestazioni del modello addestrato rispetto a benchmark o set di dati personalizzati. Il processo di valutazione prevede in genere fasi per creare una ricetta di valutazione che punti al modello addestrato, specificare set di dati e metriche di valutazione, inviare un job separato per la valutazione e valutare le prestazioni rispetto a benchmark standard o dati personalizzati. Il processo di valutazione genera i parametri delle prestazioni archiviati nel bucket Amazon S3.

### Note

Il processo di valutazione descritto in questo argomento è un processo offline. Il modello viene testato sulla base di benchmark fissi con risposte predefinite, anziché essere valutato in tempo reale o tramite interazioni utente dal vivo. Per una valutazione in tempo reale, puoi testare il modello dopo averlo distribuito su Amazon Bedrock chiamando [Amazon](#) Bedrock Runtime. APIs

## Argomenti

- [Prerequisiti](#)
- [Attività di benchmarking disponibili](#)
- [Configurazioni specifiche di una valutazione](#)
- [Esecuzione di job di addestramento per la valutazione](#)
- [Valutazione e analisi dei risultati della valutazione](#)
- [Best practice e risoluzione dei problemi di valutazione](#)
- [Sottoattività disponibili](#)
- [Valutazione del modello di ragionamento](#)
- [Valutazione RFT](#)
- [Implementazione di funzioni premi](#)

## Prerequisiti

Prima di avviare un job di addestramento per la valutazione, verifica i seguenti requisiti.

- Un modello SageMaker Amazon Nova addestrato all'intelligenza artificiale di cui desideri valutarne le prestazioni.
- Ricetta Amazon Nova di base per la valutazione. Per ulteriori informazioni, consulta [???](#).

## Attività di benchmarking disponibili

È disponibile un pacchetto di codice di esempio che dimostra come calcolare le metriche di benchmark utilizzando la funzionalità di valutazione del modello SageMaker AI per Amazon Nova. [Per accedere ai pacchetti di codice, consulta sample-N. ova-ligtheval-custom-task](#)

Di seguito è riportato un elenco di benchmark standard di settore disponibili. È possibile specificare i benchmark seguenti nel parametro `eval_task`.

Benchmark disponibili per la valutazione del modello

| Benchmark | Modalità | Description                                                                                                                | Metriche    | Strategia | Sottoattività disponibile |
|-----------|----------|----------------------------------------------------------------------------------------------------------------------------|-------------|-----------|---------------------------|
| mmlu      | Testo    | Massive Multitask Language Understanding (MMLU)<br>- Verifica la conoscenza di 57 materie.                                 | accuratezza | zs_cot    | Sì                        |
| mmlu_pro  | Testo    | MMLU - Sottinsieme professionale<br>- Incentrato su domini professionali come legge, medicina, contabilità e ingegneria.   | accuratezza | zs_cot    | No                        |
| bbh       | Testo    | Attività di ragionamento avanzato - Una raccolta di problemi impegnativi che mettono alla prova le capacità cognitive e di | accuratezza | fs_cot    | Sì                        |



| Benchmark  | Modalità | Description                                                                                                                              | Metriche    | Strategia | Sottoattività disponibile |
|------------|----------|------------------------------------------------------------------------------------------------------------------------------------------|-------------|-----------|---------------------------|
|            |          | risoluzione dei problemi di livello superiore.                                                                                           |             |           |                           |
| gpqa       | Testo    | Risposta a domande di fisica generale - Valuta la comprensione di concetti di fisica e le relative capacità di risoluzione dei problemi. | accuratezza | zs_cot    | No                        |
| matematica | Testo    | Risoluzione di problemi matematici - Misura il ragionamento matematico su argomenti quali algebra, calcolo e problemi testuali.          | exact_match | zs_cot    | Sì                        |

| Benchmark     | Modalità | Description                                                                                                                                            | Metriche    | Strategia | Sottoattività disponibile |
|---------------|----------|--------------------------------------------------------------------------------------------------------------------------------------------------------|-------------|-----------|---------------------------|
| strong_reject | Testo    | Attività di controllo della qualità<br>- Verifica la capacità del modello di rilevare e rifiutare contenuti inappropriati, dannosi o errati.           | deflection  | zs        | Sì                        |
| ifeval        | Testo    | Valutazione che segue istruzioni - Misura la precision e con cui un modello segue le istruzion i fornite e completa le attività secondo le specifiche. | accuratezza | zs        | No                        |

| Benchmark | Modalità               | Description                                                                                                                                                                                                                                                                                                                                          | Metriche | Strategia | Sottoattività disponibile |
|-----------|------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------|-----------|---------------------------|
| gen_qa    | Multimodale (immagine) | Valutazione personale del set di dati: consente di fornire il proprio set di dati per il benchmarking, confrontando gli output del modello con le risposte di riferimento con metriche come ROUGE e BLEU. gen_qasupport l'inferenza delle immagini per i modelli basati su Amazon Nova Lite o Amazon Nova Pro. Supporta anche Bring-Your-Own Metrics | tutto    | gen_qa    | No                        |

| Benchmark | Modalità    | Description                                                                                                                                                                    | Metriche    | Strategia | Sottoattività disponibile |
|-----------|-------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------|-----------|---------------------------|
|           |             | lambda. (Per la valutazione RFT, usa la ricetta RFT eval)                                                                                                                      |             |           |                           |
| mmmu      | Multimodale | Massive Multidiscipline Multimodal Understanding (MMMU): benchmark a livello universitario che comprende domande a scelta multipla e domande aperte relative a 30 discipline.) | accuratezza | zs_cot    | Sì                        |

| Benchmark | Modalità | Description                                                                                                                                                                                                              | Metriche | Strategia | Sottoattività disponibile |
|-----------|----------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------|-----------|---------------------------|
| llm_judge | Testo    | LLM-as-a-Judge<br>Confronto delle preferenze: utilizza un modello Nova Judge per determinare la preferenza tra le risposte accoppiate (B rispetto a A) per i prompt, calcolando la probabilità che B sia preferito ad A. | tutto    | judge     | No                        |

| Benchmark    | Modalità               | Description                                                                                                                                                                  | Metriche | Strategia | Sottoattività disponibile |
|--------------|------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------|-----------|---------------------------|
| mm_llm_judge | Multi-Modal (immagine) | Questo nuovo benchmark si comporta allo stesso modo del precedent e benchmark basato su testo.<br>llm_judge<br>L'unica differenza è che supporta l'inferenza delle immagini. | tutto    | judge     | No                        |

| Benchmark        | Modalità | Description                                                                                                                                                                                                                                                                                                                                            | Metriche | Strategia | Sottoattività disponibile |
|------------------|----------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------|-----------|---------------------------|
| rubric_llm_judge | Testo    | Rubric Judge è un modello di valutazione avanzato LLM-as-a-judge basato su Nova 2.0 Lite. A differenza del <a href="#">modello di arbitro originale</a> che fornisce solo verdetti di preferenza, Rubric Judge genera dinamicamente criteri di valutazione personalizzati su misura per ogni richiesta e assegna punteggi granulari su più dimensioni. | tutto    | judge     | No                        |

| Benchmark                 | Modalità | Description                                                                                                                                                                  | Metriche    | Strategia | Sottoattività disponibile |
|---------------------------|----------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------|-----------|---------------------------|
| aime_2024                 | Testo    | AIME 2024<br>- American Invitational Mathematics Examination: problemi relativi alla verifica del ragionamento matematico avanzato e alla risoluzione dei problemi           | exact_match | zs_cot    | No                        |
| calendario_pianificazione | Testo    | Natural Plan<br>- Calendar<br>- Pianificazione delle attività, test delle attività, capacità di pianificazione per la pianificazione di riunioni su più giorni e più persone | exact_match | fs        | No                        |



| Benchmark | Modalità | Description                                                                                                                                           | Metriche | Strategia | Sottoattività disponibile |
|-----------|----------|-------------------------------------------------------------------------------------------------------------------------------------------------------|----------|-----------|---------------------------|
| humaneval | Testo    | HumanEval -<br>Un set di dati di riferimento progettato per valutare le capacità di generazione di codice di modelli linguistici di grandi dimensioni | pass@1   | zs        | No                        |

## Configurazioni specifiche di una valutazione

Di seguito sono riportati i componenti chiave della ricetta e le indicazioni su come modificarli in base ai casi d'uso.

### Comprensione e modifica delle ricette

#### Configurazione run generale

```
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:** un nome descrittivo per il processo di valutazione.
- **model\_type:** specifica la variante del modello Nova da utilizzare. Non modificare manualmente questo campo. Le opzioni includono:

- Amazon. nova-micro-v1:01:28 K
- amazzone. nova-lite-v1:0:300 k
- amazzone. nova-pro-v1:0:300 k
- amazon.nova-2-lite-v 1:0:256k
- `model_name_or_path`: il percorso del modello di base o il percorso S3 per il checkpoint post-addestrato. Le opzioni includono:
  - nova-micro/prod
  - nova-lite/prod
  - nova-pro/prod
  - nova-lite-2/prod
- Percorso S3 per il percorso di checkpoint post-addestrato (`s3:customer-escrow-111122223333-smjtj-<unique_id>/<training_run_name>`)

#### Note

##### Valutare un modello post-addestrato

Per valutare un modello post-addestrato dopo un job di addestramento Nova SFT, segui questa procedura dopo aver eseguito correttamente un job di addestramento. L'addestramento ha esito positivo se alla fine dei log viene visualizzato il messaggio "Training is complete". Nel bucket di output è inoltre disponibile un file `manifest.json` contenente la posizione del checkpoint. Questo file si trova all'interno di un file `output.tar.gz` nella posizione S3 di output. Per procedere con la valutazione, utilizza questo checkpoint impostandolo come valore per `run.model_name_or_path` nella configurazione della ricetta.

- `replica`: Il numero di istanze di calcolo da utilizzare per l'inferenza distribuita (esecuzione dell'inferenza su più nodi). Imposta `replica > 1` per abilitare l'inferenza multinodo, che accelera la valutazione. Se `replica` vengono specificati entrambi `instance_count` e `instance_count` ha la precedenza. Tieni presente che le repliche multiple si applicano solo ai lavori di formazione SageMaker sull'intelligenza artificiale, non.
- `data_s3_path`: percorso Amazon S3 del set di dati di input. Questo campo è obbligatorio, ma deve essere sempre lasciato vuoto.
- `mlflow_tracking_uri`: (Facoltativo) La posizione del server di MLflow tracciamento (necessaria solo su SMHP)

- `mlflow_experiment_name`: (Facoltativo) Nome dell'esperimento per raggruppare insieme le esecuzioni ML correlate
- `mlflow_run_name`: (Facoltativo) Nome personalizzato per un corso di formazione specifico all'interno di un esperimento

## Configurazione evaluation

```
evaluation:
 task: mmlu
 strategy: zs_cot
 subtask: abstract_algebra
 metric: accuracy
```

- `task`: specifica il benchmark o l'attività di valutazione da utilizzare. Le attività supportate includono:
  - `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`: definisce l'approccio di valutazione.
  - `zs_cot`: Zero-shot Chain of Thought: un approccio per suggerire modelli linguistici di grandi dimensioni che incoraggia il step-by-step ragionamento senza richiedere esempi espliciti.

- **fs\_cot**: Few-shot Chain of Thought: un approccio che fornisce alcuni esempi di step-by-step ragionamento prima di chiedere al modello di risolvere un nuovo problema.
- **zs**: Zero-shot - Un approccio per risolvere un problema senza esempi di addestramento precedenti.
- **gen\_qa**: strategia specifica per utilizzare un set di dati personalizzato.
- **judge**: Strategia specifica per Nova LLM come giudice e. **mm\_llm\_judge**
- **subtask**: facoltativo. Componenti specifici dell'attività di valutazione. Per un elenco completo delle sottoattività disponibili, consulta [???](#).
  - Controlla le sottoattività supportate in Attività di benchmarking disponibili.
  - Se non sono presenti benchmark per sottoattività, è consigliabile rimuovere questo campo.
- **metric**: la metrica di valutazione da utilizzare.
  - **accuracy**: percentuale di risposte corrette.
  - **exact\_match**: per il benchmark math, restituisce la velocità con cui le stringhe previste nell'input corrispondono esattamente ai loro riferimenti.
  - **deflection**: per il benchmark strong reject, restituisce la deviazione relativa rispetto al modello di base e la differenza nelle metriche di significatività.
  - **all**:

Per un benchmark Bring Your Own Dataset e **gen\_qa**, restituisce le seguenti metriche:

- **rouge1**: misura la sovrapposizione di unigrammi (parole singole) tra il testo generato e quello di riferimento.
- **rouge2**: misura la sovrapposizione di bigrammi (due parole consecutive) tra il testo generato e quello di riferimento.
- **rougeL**: misura la sottosequenza comune più lunga tra testi, tenendo conto di lacune nella corrispondenza.
- **exact\_match**: punteggio binario (0 oppure 1) che indica se il testo generato corrisponde esattamente al testo di riferimento, carattere per carattere.
- **quasi\_exact\_match**: simile alla corrispondenza esatta, ma meno rigida, in genere ignora le differenze tra maiuscole e minuscole, punteggiatura e spazi.
- **f1\_score**: media armonica di precisione e richiamo, che misura la sovrapposizione di parole tra le risposte previste e quelle di riferimento.
- **f1\_score\_quasi**: simile a **f1\_score**, ma con una corrispondenza meno rigida, utilizza un

- **bleu**: misura la precisione delle corrispondenze in n-grammi tra il testo generato e quello di riferimento, comunemente utilizzate nella valutazione delle traduzioni.

Inoltre `llm_judgemm_llm_judge`, porta il tuo benchmark del set di dati, restituisci le seguenti metriche:

- **a\_scores**: numero di vittorie per `response_A` nei passaggi di valutazione avanti e indietro.
- **a\_scores\_stderr**: errore standard di `response_A_scores` nei giudizi a coppie.
- **b\_scores**: misura il numero di vittorie per `response_B` nei passaggi di valutazione avanti e indietro.
- **a\_scores\_stderr**: errore standard di `response_B_scores` nei giudizi a coppie.
- **ties**: numero di giudizi in cui `response_A` e `response_B` sono valutati in modo uguale.
- **ties\_stderr**: errore standard di `ties` nei giudizi a coppie.
- **inference\_error**: numero di giudizi che non è stato possibile valutare correttamente.
- **score**: punteggio aggregato basato sulle vittorie nei passaggi avanti e indietro per `response_B`.
- **score\_stderr**: punteggio aggregato basato sulle vittorie nei passaggi avanti e indietro per `response_B`.
- **inference\_error\_stderr**: errore standard del punteggio aggregato nei giudizi a coppie.
- **winrate**: la probabilità che `response_B` venga preferito rispetto a `response_A` calcolato utilizzando la probabilità di Bradley-Terry.
- **lower\_rate**: limite inferiore (percentile 2,5) del tasso di successo stimato derivante dal campionamento bootstrap.
- **upper\_rate**: limite superiore (percentile 97,5) del tasso di successo stimato derivante dal campionamento bootstrap.

### Configurazione inference (facoltativa)

```
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`: numero massimo di token da generare. Deve essere un numero intero. Non disponibile per LLM-as-a-judge.
- `top_k`: numero di token con la più alta probabilità da considerare. Deve essere un numero intero.
- `top_p`: soglia di probabilità cumulativa per il campionamento tramite token. Deve essere un valore decimale compreso tra 1,0 e 0,0.
- `temperature`: casualità nella selezione dei token (valore più alto = casualità maggiore), mantieni il valore pari a 0 per rendere il risultato deterministico. Tipo decimale, il valore minimo è 0.
- `top_logprobs`: Il numero di migliori logprobs da restituire nella risposta di inferenza. Questo valore deve essere un numero intero compreso tra 0 e 20. I logprobs contengono i token di output considerati e le probabilità di registro di ogni token di output restituito nel contenuto del messaggio.
- `reasoning_effort`: controlla il comportamento di ragionamento per modelli in grado di ragionare. Imposta `reasoning_effort` solo quando `model_type` specifica un modello in grado di ragionare (attualmente). `amazon.nova-2-lite-v1:0:256k` Le opzioni disponibili sono nulle (valore predefinito se non impostato; disabilita il ragionamento), basse o alte.

## Formato di output logaritmico

Se `top_logprobs` configurato nelle impostazioni di inferenza, l'output di valutazione include le probabilità di registro a livello di token nei file parquet. Ogni posizione del token contiene un dizionario dei migliori token candidati con le relative probabilità di registro nella seguente struttura:

```
{
 "Ġint": {"logprob_value": -17.8125, "decoded_value": " int"},
 "Ġthe": {"logprob_value": -2.345, "decoded_value": " the"}
}
```

Ogni voce del token contiene:

- `logprob_value`: Il valore di probabilità logaritmica per il token
- `decoded_value`: La rappresentazione di stringa decodificata leggibile dall'uomo del token

Il token tokenizer non elaborato viene utilizzato come chiave del dizionario per garantire l'unicità, fornendo al contempo un'interpretazione leggibile. `decoded_value`

## Esempi di ricette di valutazione

Amazon Nova offre quattro diversi tipi di ricette di valutazione. [Tutte le ricette sono disponibili nell'archivio delle ricette. SageMaker HyperPod GitHub](#)

### Ricette di benchmark testuali generali

Queste ricette consentono di valutare le funzionalità fondamentali dei modelli Amazon Nova attraverso una suite completa di benchmark di solo testo.

Formato della ricetta: `xxx_general_text_benchmark_eval.yaml`.

### Ricette di benchmark Bring Your Own Dataset

Queste ricette consentono di utilizzare un set di dati personalizzato per il benchmarking e confrontare i risultati del modello con risposte di riferimento utilizzando diversi tipi di metriche.

Formato della ricetta: `xxx_ bring_your_own_dataset_eval.yaml`.

### Requisiti Bring Your Own Dataset

Formato del file:

- Singolo file `gen_qa.jsonl` contenente esempi di valutazione. Il nome del file deve essere esattamente `gen_qa.jsonl`.
- È necessario caricare il set di dati in una posizione S3 a cui possano accedere i lavori di formazione SageMaker sull'intelligenza artificiale.
- Il file deve seguire il formato dello schema richiesto per il set di dati Q&A generale.

Requisiti del formato dello schema: ogni riga del `.jsonl` file deve essere un oggetto JSON con i seguenti campi.

- Campi obbligatori.

`query`: stringa contenente la domanda o l'istruzione che richiede una risposta.

`response`: stringa contenente l'output del modello previsto.

- Campi facoltativi.

`system`: stringa contenente il prompt di sistema che imposta il comportamento, il ruolo o la personalità del modello di intelligenza artificiale prima che elabori la query.

**images:** Array contenente un elenco di oggetti con attributi di dati (stringhe di immagini codificate in Base64).

**metadata:** Stringa contenente i metadati associati alla voce a scopo di etichettatura.

### Esempio di inserimento

```
{
 "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 ..."
 }
]
}
```

Per utilizzare il set di dati personalizzato, modifica la ricetta di valutazione aggiungendo i seguenti campi obbligatori senza modificare la configurazione esistente:

```
evaluation:
 task: gen_qa
 strategy: gen_qa
 metric: all
```



## Limitazioni

- È consentito un solo file `.jsonl` per valutazione.
- Il file deve seguire rigorosamente lo schema definito.

## Porta le tue metriche

Puoi utilizzare le tue metriche per personalizzare completamente il flusso di lavoro di valutazione del modello con funzionalità di preelaborazione, postelaborazione e metriche personalizzate. La preelaborazione consente di elaborare i dati di input prima di inviarli al server di inferenza, mentre la postelaborazione consente di personalizzare il calcolo delle metriche e restituire metriche personalizzate in base alle proprie esigenze.

Segui questi passaggi per utilizzare le tue metriche con un SDK di valutazione personalizzato.

1. Se non l'hai ancora fatto, [crea prima una AWS Lambda funzione](#). Account AWS
2. Scarica il `nova-custom-eval-layer.zip` file predefinito dal [GitHub repository](#). Puoi utilizzare questo SDK di valutazione personalizzato Nova open source per convalidare i payload di input e output per la tua funzione personalizzata e fornire un'interfaccia unificata per l'integrazione con la valutazione delle metriche Bring your own di Nova durante la formazione.
3. Carica il layer Lambda personalizzato utilizzando il seguente comando:

```
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. Aggiungi questo livello come livello personalizzato alla tua funzione Lambda, insieme al AWS livello richiesto: `AWSLambdaPowertoolsPythonV3-python312-arm64` (richiesto per la pydantic dipendenza).
5. Aggiorna il codice Lambda utilizzando l'esempio fornito, modificando il codice secondo necessità. Questo codice di esempio crea una funzione Lambda per la valutazione personalizzata di Nova con fasi di preelaborazione e post-elaborazione per la valutazione del modello.

```
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. Concedi a Lambda l'accesso al processo di valutazione. Assicurati che il ruolo di esecuzione specificato per il processo di valutazione includa una policy per richiamare la tua funzione Lambda. Ecco una policy di esempio:

## 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. Esamina lo schema del payload Lambda. La tabella seguente elenca lo schema di richiesta e risposta Lambda. Puoi convalidare lo schema utilizzando l'SDK di valutazione personalizzato Nova.

|               | Payload della richiesta Lambda                                                                                                                            | Payload di risposta Lambda                                                                                                                                                                                                      |
|---------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Preprocessor  | <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>                                               |
| Postprocessor | <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},     {"metric": "length_ratio", "value": 0.8}   ] }</pre> |

## 8. Modificate il file della ricetta. Ecco un esempio.

```
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`: Amazon Resource Name (ARN) per la tua funzione Lambda che gestisce la preelaborazione e la postelaborazione.
- `lambda_type`: «`custom_metrics`» o «`rft`».
- `preprocessing`: Se abilitare le operazioni di preelaborazione personalizzate.
- `postprocessing`: Se abilitare le operazioni di post-elaborazione personalizzate.
- `aggregation`: Funzione di aggregazione integrata (opzioni valide: `min`, `max`, `average`, `sum`).

## Limitazioni

- Le metriche Bring your own si applicano solo ai set di dati di input di testo.
- I set di dati di input multimodali non sono supportati.
- La fase di preelaborazione non elabora il campo dei metadati.

## Ricette di benchmark Nova LLM-as-a-judge

Nova LLM Judge è una funzionalità di valutazione del modello che consente di confrontare la qualità delle risposte di un modello con le risposte del modello di base utilizzando un set di dati personalizzato. Accetta un set di dati contenente prompt, risposte di base e risposte di richiesta di verifica, quindi utilizza un modello Nova Judge per fornire una metrica del tasso di successo basata sulla probabilità di [Bradley-Terry](#) con confronti a coppie. Formato della ricetta: `xxx_llm_judge_eval.yaml`.

## Requisiti dei set di dati Nova LLM

### Formato del file:

- Singolo file `llm_judge.jsonl` contenente esempi di valutazione. Il nome del file deve essere esattamente `llm_judge.jsonl`.
- Devi caricare il set di dati in una sede S3 a cui possono accedere i lavori di formazione sull' SageMaker intelligenza artificiale.
- Il file deve seguire il formato dello schema richiesto per il set di dati `llm_judge`.
- Il set di dati di input deve garantire che tutti i record abbiano una lunghezza di contesto inferiore a 12.000.

Formato dello schema - Ogni riga del file `.jsonl` deve essere un oggetto JSON con i campi seguenti.

- Campi obbligatori.

`prompt`: stringa contenente il prompt per la risposta generata.

`response_A`: stringa contenente la risposta di base.

`response_B`: stringa contenente la risposta alternativa da confrontare con la risposta di base.

### Esempio di inserimento

```
{
 "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."
}
```

Per utilizzare un set di dati personalizzato, modifica la ricetta di valutazione con i seguenti campi obbligatori, senza modificare alcun contenuto:

```
evaluation:
 task: llm_judge
 strategy: judge
 metric: all
```

## Limitazioni

- È consentito un solo file `.jsonl` per valutazione.
- Il file deve seguire rigorosamente lo schema definito.
- I modelli Nova Judge sono gli stessi per quanto riguarda le specifiche Micro/Lite/Pro.
- Attualmente i modelli Judge personalizzati non sono supportati.

Nova LLM in qualità di giudice per le ricette di riferimento multimodali (immagini)

Nova LLM Judge for multi-modal (immagine), abbreviazione di Nova MM\_LLM Judge, è una funzionalità di valutazione del modello che consente di confrontare la qualità delle risposte di un modello con le risposte di un modello di base utilizzando un set di dati personalizzato. Accetta un set di dati contenente prompt, risposte di base e risposte challenger e immagini sotto forma di stringa codificata in Base64, quindi utilizza un modello Nova Judge per fornire una metrica del tasso di vittoria basata sulla probabilità di [Bradley-Terry](#) attraverso confronti a coppie. Formato della ricetta: `xxx_mm_llm_judge_eval.yaml`.

## Requisiti dei set di dati Nova LLM

Formato del file:

- Singolo file `mm_llm_judge.jsonl` contenente esempi di valutazione. Il nome del file deve essere esatto. `llm_judge.jsonl`
- Devi caricare il set di dati in una posizione S3 a cui i responsabili della formazione sull' SageMaker intelligenza artificiale possano accedervi.
- Il file deve seguire il formato dello schema richiesto per il set di dati `mm_llm_judge`.
- Il set di dati di input dovrebbe garantire che tutti i record abbiano una lunghezza di contesto inferiore a 12 k, escluso l'attributo dell'immagine.

Formato dello schema - Ogni riga del file `.jsonl` deve essere un oggetto JSON con i campi seguenti.

- Campi obbligatori.

`prompt`: stringa contenente il prompt per la risposta generata.

`images`: Array contenente un elenco di oggetti con attributi di dati (i valori sono stringhe di immagine codificate in Base64).

`response_A`: stringa contenente la risposta di base.

`response_B`: stringa contenente la risposta alternativa da confrontare con la risposta di base.

### Esempio di inserimento

Per motivi di leggibilità, l'esempio seguente include nuove righe e rientri, ma nel set di dati effettivo, ogni record deve trovarsi su una sola riga.

```
{
 "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"
```



```
}
```

Per utilizzare un set di dati personalizzato, modifica la ricetta di valutazione con i seguenti campi obbligatori, senza modificare alcun contenuto:

```
evaluation:
 task: mm_llm_judge
 strategy: judge
 metric: all
```

## Limitazioni

- È consentito un solo file `.jsonl` per valutazione.
- Il file deve seguire rigorosamente lo schema definito.
- I modelli Nova MM Judge supportano solo il riferimento alle immagini.
- I modelli Nova MM Judge sono gli stessi per tutte le specifiche di Amazon Nova Micro, Amazon Nova Lite e Amazon Nova Pro.
- Attualmente i modelli Judge personalizzati non sono supportati.
- L'URI di immagine Amazon S3 non è supportato.
- Il set di dati di input dovrebbe garantire che tutti i record abbiano una lunghezza di contesto inferiore a 12 k, escluso l'attributo `images`.

## Valutazione dei punti di controllo CPT (pre-formazione continua)

La valutazione dei modelli CPT (Continuous Pre-Training) può essere più difficile rispetto ai modelli sottoposti a SFT (supervised fine tuning), in quanto i modelli CPT spesso non sono in grado di seguire le istruzioni. Invece di seguire le istruzioni, i modelli CPT funzioneranno come modelli di completamento, il che significa che cercheranno solo di continuare lo schema fornito con la sequenza dei token di input. Data questa limitazione, i set di dati di valutazione tipici potrebbero non funzionare correttamente a causa del formato «Q&A» degli input: invece di rispondere alla domanda, il modello cercherà semplicemente di continuare con la stessa domanda. Tuttavia, formattando i set di dati in un modo specifico per richiedere ai modelli uno stile di completamento, possiamo comprendere le prestazioni del modello.

Segui i passaggi seguenti per capire come eseguire una valutazione su un modello continuo preaddestrato utilizzando il flusso di lavoro di valutazione di Nova Forge.

## Preparazione e formattazione dei set di dati

La valutazione di un modello CPT sfrutta il flusso di lavoro [Bring Your Own Dataset](#) già esistente già fornito nell'esperienza di valutazione del modello Nova Forge. Tuttavia, le query all'interno del set di dati devono essere formattate in un formato puramente «di completamento» poiché i modelli CPT non risponderanno alle richieste standard in stile domanda nello stesso modo in cui farebbe un modello SFT.

Un'altra importante limitazione frequente dei modelli sottoposti esclusivamente al CPT è la loro incapacità di generare token STOP o di fine sequenza: ciò significa che il modello continuerà a generare token fino a quando non verrà interrotto con forza (come con il parametro `max_new_tokens`). Data questa limitazione, la migliore pratica consiste nel valutare i modelli utilizzando risposte a token singolo (come la scelta multipla) per garantire che il modello non continui a generare output indesiderati che non sono necessari dopo la richiesta.

Ad esempio, un tipico set di dati di valutazione (come MMLU, GPQA, MATH, ecc.) potrebbe porre al modello una domanda come:

```
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.)
```

Tuttavia, un modello CPT non capirebbe come rispondere correttamente a questa domanda a causa della mancanza di una regolazione precisa delle istruzioni che seguono. Pertanto, i modelli CPT devono essere richiesti con uno stile di completamento, ad esempio:

```
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.)
```

Dopo il controllo dell'inferenza, i logprobs di output generati dal modello forniranno dettagli sul fatto che il modello stia elaborando correttamente l'input e generando la risposta corretta. Non è garantito che il modello produca sempre la risposta esatta (in questo caso, la lettera D) prevista, tuttavia dovrebbe essere presente all'interno dei logprobs se il modello funziona correttamente.

Un altro esempio di prompt di stile di completamento non a scelta multipla:

```
The capital of France is

(Expected answer of Paris)
```

Ci aspetteremmo che il modello produca una risposta di «Paris» o veda il token corrispondente a «Paris» da qualche parte nell'output di logprobs.

### Formattazione del set di dati

La valutazione CPT sfrutta il flusso di lavoro esistente di [Bring Your Own](#) Dataset. I dati devono essere formattati nel formato «risposta alla query» in un file JSONL separato da nuove righe.

Un esempio di set di dati contenente 4 voci:

```
{"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"}
```

Ogni riga deve contenere:

- **query:** Il testo richiesto per il completamento
- **response:** Il completamento previsto (verità fondamentale)

Il modello riceverà un input di testo non elaborato senza formattazione della chat. I modelli CPT in genere non sono ancora addestrati su token speciali e non rispondono correttamente ai modelli di chat, quindi quando viene richiesta al modello SOLO la stringa fornita nella query verrà inviata al modello (con un [BOS] token aggiuntivo aggiunto automaticamente).

### Configurazione della ricetta

Ecco un esempio di ricetta configurata per valutare un modello CPT:

```
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
```

Modifiche chiave per la valutazione CPT:

- `checkpoint_is_instruction_tuned: "false"`

Si tratta di un nuovo parametro aggiunto specificamente per supportare le esecuzioni di valutazione sui checkpoint CPT. L'impostazione di `checkpoint_is_instruction_tuned` su `false` disabiliterà il modello di chat Amazon Nova predefinito che normalmente include il prompt di input.

- `top_logprobs: 5`

Le probabilità di log (logprobs) rivelano la distribuzione della fiducia del modello tra i possibili token next, aiutandoti a valutare se il modello ha appreso i completamenti previsti durante il pre-addestramento. In genere, se il modello funziona come previsto, dovremmo vedere la risposta prevista (ad esempio, «A», «B», ecc.) come token di output generato o come token nei logprobs.

- `max_new_tokens: 1`

I modelli CPT in genere non sono ancora stati addestrati a generare speciali token «stop» o «end of sequence» per segnalare quando interrompere l'inferenza. Ciò significa che il modello in genere continuerà a generare nuovi token fino al raggiungimento della lunghezza massima specifica del token, con conseguente inferenza non necessaria. In genere, limitare `max_new_tokens` a 1 e fornire un prompt in grado di valutare il modello in base a una singola risposta (come una domanda a scelta multipla) è il modo più efficiente per richiedere il modello. L'impostazione di `max_new_tokens` su 1 garantisce che non vengano generati token spazzatura aggiuntivi.

## Parametri chiave

- `checkpoint_is_instruction_tuned`: deve essere impostato su (o come booleano) per disabilitare i modelli di chat "false" false
- `top_logprobs`: 5, consigliato per vedere come il modello sta imparando durante il CPT
- `compito`: Deve essere: i modelli CPT non possono utilizzare `gen_qa` benchmark che seguono le istruzioni come MMLU o MATH
- `strategia`: Deve essere `gen_qa`
- `max_new_tokens`: si consiglia di mantenere un valore basso (1-5) poiché i modelli CPT eseguono il completamento, non la generazione

## Esecuzione di job di addestramento per la valutazione

Inizia un processo di formazione utilizzando il seguente taccuino di esempio. Fate riferimento al seguente taccuino come esempio per eseguire il processo di formazione di valutazione. Per ulteriori informazioni, consulta [Utilizzare uno stimatore di SageMaker intelligenza artificiale per eseguire un processo di formazione](#).

### Tabelle di riferimento

Prima di eseguire il notebook, fai riferimento alle seguenti tabelle di riferimento per selezionare l'URI delle immagini e le configurazioni delle istanze.

### Selezione dell'URI delle immagini

| Recipe                            | URI immagine                                                                                        |
|-----------------------------------|-----------------------------------------------------------------------------------------------------|
| URI delle immagini di valutazione | <code>708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-TJ-Eval-V2-latest</code> |

### Selezione del tipo e del numero di istanze

| Modello           | Tipo di processo      | Tipo di istanza | Numero di istanze consigliato | Numero di istanze consentito |
|-------------------|-----------------------|-----------------|-------------------------------|------------------------------|
| Amazon Nova Micro | Valutazione (SFT/DPO) | g5.12xlarge     | 1                             | 1 - 16                       |
| Amazon Nova Lite  | Valutazione (SFT/DPO) | g5.12xlarge     | 1                             | 1 - 16                       |
| Amazon Nova Pro   | Valutazione (SFT/DPO) | p5.48xlarge     | 1                             | 1 - 16                       |

## Notebook di esempio

Il seguente notebook di esempio mostra come eseguire un job di addestramento per la valutazione.

```
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})

```

## Valutazione e analisi dei risultati della valutazione

Una volta completato correttamente il processo di valutazione, è possibile valutare e analizzare i seguendo questa procedura.

Per valutare e analizzare i risultati, procedi nel seguente modo.

1. Comprendi la struttura della posizione di output. I risultati vengono archiviati nella posizione di output specificata di Amazon S3 come file compresso:

```
s3://your-bucket/output/benchmark-name/
```

```

job_name/
 ### output/
 ### output.tar.gz

```

2. Scarica il file `output.tar.gz` dal bucket. Estrai il contenuto per visualizzarlo.

```

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` - File JSON delle metriche di output
  - `details_<task_name>_#_<datetime>.parquet` - File di output di inferenza (ad eccezione di `strong_reject`)
  - `events.out.tfevents.[timestamp]` - file TensorBoard di output
  - `inference_output.jsonl` - File di output di inferenza pulito (solo per attività `gen_qa`)
3. Visualizza i risultati in TensorBoard. Per visualizzare le metriche di valutazione:
    1. Carica la cartella estratta in un bucket S3
    2. Passa all' SageMaker IA TensorBoard
    3. Seleziona “Cartelle S3”
    4. Aggiungi il percorso della cartella S3
    5. Attendi il completamento della sincronizzazione
  4. Analizza gli output di inferenza. Tutte le attività di valutazione, tranne `llm_judge` e `strong_reject`, includono i seguenti campi per l'analisi nell'output dell'inferenza.
    - `full_prompt`- Il prompt utente completo inviato al modello utilizzato per l'attività di valutazione.
    - `gold`- Il campo che contiene le risposte corrette come specificato dal set di dati.



- **metrics**- Il campo che contiene le metriche valutate sulla singola inferenza. I valori che richiedono l'aggregazione non hanno un valore sui singoli output di inferenza.
- **predictions**- Il campo che contiene un elenco dell'output del modello per il prompt specificato.
- **pred\_logits**- Il campo che contiene i token di output considerati e le probabilità di registro di ogni token di output restituito nel contenuto del messaggio.

Esaminando questi campi, è possibile determinare la causa delle differenze nelle metriche e comprendere il comportamento dei modelli personalizzati.

Per `llm_judge`, il file di output dell'inferenza contiene i seguenti campi nel campo delle metriche per coppia di valutazioni.

- **forward\_output** - Le preferenze non elaborate di Judge durante la valutazione nell'ordine diretto (`response_A`, `response_B`).
- **backward\_output** - Le preferenze non elaborate di Judge durante la valutazione nell'ordine inverso (`response_B`, `response_A`).
- **Pairwise metrics** - Metriche calcolate per coppia di valutazioni avanti e indietro, tra cui `a_scores`, `b_scores`, `ties`, `inference-score` e `score`.

 **Note**

Metriche aggregate come `winrate` sono disponibili solo nei file dei risultati di riepilogo, non basate su giudizi individuali.

Per `gen_qa`, il file `inference_output.jsonl` contiene i seguenti campi per ogni oggetto JSON:

- **prompt** - Il prompt finale inviato al modello
- **inference** - L'output di inferenza non elaborato del modello
- **gold** - La risposta target dal set di dati di input
- **metadata** - La stringa di metadati del set di dati di input, se fornita

## Best practice e risoluzione dei problemi di valutazione

### Best practice

Di seguito sono elencate alcune best practice per il processo di valutazione.

- Mantieni i percorsi di output organizzati per modello e tipo di benchmark.
- Mantieni convenzioni di denominazione coerenti per semplificare il monitoraggio.
- Salva i risultati estratti in una posizione sicura.
- Monitora lo stato di TensorBoard sincronizzazione per il corretto caricamento dei dati.

### Risoluzione dei problemi

È possibile utilizzare CloudWatch il gruppo di log `/aws/sagemaker/TrainingJobs` per addestrare i registri degli errori dei processi.

#### Guasto al nucleo del motore

Problema:

Se stai vedendo:

```
RuntimeError: Engine core initialization failed.
```

Causa:

Sebbene si tratti di un errore generale che può avere più cause, in genere si verifica quando c'è una mancata corrispondenza tra il checkpoint del modello che stai tentando di caricare e il tipo di modello specificato. Ad esempio, volete valutare un checkpoint del modello Nova 2.0 lite ottimizzato, ma il tipo di modello fornito è di tipo 1.0. ad es. `amazon.nova-micro-v1:0:128k`

La mappatura corretta dovrebbe essere

```
model_type: amazon.nova-2-lite-v1:0:256k
model_name_or_path: nova-lite-2/prod # or s3://escrow_bucket/model_location
```

Prevenzione:

Controlla che `model_name_or_path` sia mappato a destra `model_type` prima di inviare il lavoro di valutazione.

## Sottoattività disponibili

Di seguito sono elencate le sottoattività disponibili per la valutazione del modello in più domini, tra cui MMLU (Massive Multitask Language Understanding), BBH (Big Bench Hard), MATH e MMMU (Massive Multi-discipline Multimodal Understanding). Queste sottoattività consentono di valutare le prestazioni del modello in base a funzionalità e aree di conoscenza specifiche.

### 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 (Matematica)

```

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",
```

Valuta i tuoi modelli Nova personalizzati utilizzando vari metodi e metriche di valutazione.

In questa sezione:

- [Valutazione del modello di ragionamento](#)
- [Valutazione RFT](#)
- [Implementazione di funzioni premi](#)

## Valutazione del modello di ragionamento

Panoramica di

Il supporto del modello di ragionamento consente la valutazione con modelli Nova compatibili con il ragionamento che eseguono un ragionamento interno esplicito prima di generare risposte finali. Questa funzionalità utilizza il controllo a livello di API tramite il `reasoning_effort` parametro per abilitare o disabilitare dinamicamente la funzionalità di ragionamento, migliorando potenzialmente la qualità della risposta per attività analitiche complesse.

Modelli supportati

- `amazon.nova-2-lite-v 1:0:256k`

## Configurazione della ricetta

Abilita il ragionamento aggiungendo il `reasoning_effort` parametro alla `inference` sezione della tua ricetta:

```
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)
```

## Utilizzo del parametro `reasoning_effort`

Il `reasoning_effort` parametro controlla il comportamento di ragionamento per i modelli in grado di ragionare.

## Prerequisiti

- Compatibilità tra modelli: viene impostata `reasoning_effort` solo quando `model_type` specifica un modello in grado di ragionare (attualmente) `amazon.nova-2-lite-v1:0:256k`
- Gestione degli errori: l'utilizzo `reasoning_effort` con modelli non supportati avrà esito negativo con `ConfigValidationError: "Reasoning mode is enabled but model '{model_type}' does not support reasoning. Please use a reasoning-capable model or disable reasoning mode."`

## Opzioni disponibili

| Opzione                            | Comportamento                          | Limite di token                                 | Caso d'uso                                                                         |
|------------------------------------|----------------------------------------|-------------------------------------------------|------------------------------------------------------------------------------------|
| null<br>(impostazione predefinita) | Disattiva la modalità di ragionamento  | N/D                                             | Valutazione standard senza sovraccarico di ragionamento                            |
| low                                | Consente il ragionamento con vincoli   | 4.000 token per il ragionamento interno         | Scenari che richiedono un ragionamento conciso; ottimizza velocità e costi         |
| high                               | Consente il ragionamento senza vincoli | Nessun limite simbolico al ragionamento interno | Problemi complessi che richiedono analisi e step-by-step ragionamenti approfonditi |

| Metodo di addestramento                        | Opzioni disponibili       | Come configurare                                                                                                |
|------------------------------------------------|---------------------------|-----------------------------------------------------------------------------------------------------------------|
| SFT (regolazione di precisione supervisionata) | Solo High o Off           | Usa <code>reasoning_enabled: true</code> (high) o <code>reasoning_enabled: false</code> (off)                   |
| RFT (Reinforcement Fine-Tuning)                | Basso, Alto o Disattivato | Usa <code>reasoning_effort: low</code> o <code>reasoning_effort: high</code> . Ometti il campo da disabilitare. |



| Metodo di addestramento | Opzioni disponibili       | Come configurare                                                                                           |
|-------------------------|---------------------------|------------------------------------------------------------------------------------------------------------|
| Valutazione             | Basso, Alto o Disattivato | Usa <code>reasoning_effort</code> : low o <code>reasoning_effort</code> : high. Usa null per disabilitare. |

Quando abilitare il ragionamento

Usa la modalità di ragionamento (**low**) per **high**

- Compiti complessi di risoluzione di problemi (matematica, puzzle logici, programmazione)
- Domande analitiche in più fasi che richiedono un ragionamento intermedio
- Attività in cui spiegazioni o riflessioni dettagliate migliorano la precisione step-by-step
- Scenari in cui la qualità della risposta è prioritaria rispetto alla velocità

Usa la modalità non ragionamento (**null** ometti il parametro) per

- Domande e risposte semplici o domande fattuali
- Attività di scrittura creativa
- Quando i tempi di risposta più rapidi sono fondamentali
- Analisi comparativa delle prestazioni in cui è necessario escludere il sovraccarico di ragionamento
- L'ottimizzazione dei costi quando il ragionamento non migliora le prestazioni delle attività

Risoluzione dei problemi

Errore: «La modalità di ragionamento è abilitata ma il modello non supporta il ragionamento»

Causa: il `reasoning_effort` parametro è impostato su un valore diverso da nullo, ma quello specificato `model_type` non supporta il ragionamento.

Risoluzione:

- Verifica che il tipo di modello sia `amazon.nova-2-lite-v1:0:256k`
- Se utilizzi un modello diverso, passa a un modello in grado di ragionare o rimuovi il `reasoning_effort` parametro dalla tua ricetta

## Valutazione RFT

### Cos'è la valutazione RFT?

RFT Evaluation consente di valutare le prestazioni del modello utilizzando funzioni di ricompensa personalizzate prima, durante o dopo la formazione di reinforcement learning. A differenza delle valutazioni standard che utilizzano metriche predefinite, RFT Evaluation consente di definire criteri di successo personalizzati tramite una funzione Lambda che assegna un punteggio agli output del modello in base ai requisiti specifici.

### Perché effettuare una valutazione con RFT?

La valutazione è fondamentale per determinare se il processo di messa a punto di RL presenta:

- Migliore allineamento del modello con il caso d'uso specifico e i valori umani
- Funzionalità del modello mantenute o migliorate per le attività chiave
- Ha evitato effetti collaterali indesiderati come riduzione della fattualità, aumento della verbosità o riduzione delle prestazioni in altre attività
- Hai soddisfatto i criteri di successo personalizzati definiti dalla tua funzione di ricompensa

### Quando utilizzare la valutazione RFT

Utilizza la valutazione RFT in questi scenari:

- Prima della formazione RFT: stabilisci le metriche di base sul tuo set di dati di valutazione
- Durante l'allenamento RFT: monitora i progressi dell'allenamento con punti di controllo intermedi
- Dopo la formazione RFT: verifica che il modello finale soddisfi i tuoi requisiti
- Confronto tra modelli: valuta più versioni del modello utilizzando criteri di ricompensa coerenti

#### Note

Usa RFT Evaluation quando hai bisogno di metriche personalizzate e specifiche del dominio. Per una valutazione generica (precisione, perplessità, BLEU), utilizzate metodi di valutazione standard.

## Requisiti per il formato dei dati

### Struttura dei dati di input

I dati di input di valutazione RFT devono seguire il formato OpenAI Reinforcement Fine-Tuning. Ogni esempio è un oggetto JSON contenente:

- **messages**— Serie di turni e ruoli di conversazione `system user`
- **reference\_answer**— Risultati attesi o dati fondamentali utilizzati dalla funzione di ricompensa per il punteggio

### Esempio di formato dei dati

```
{
 "messages": [
 {
 "role": "user",
 "content": [
 {
 "type": "text",
 "text": "Solve for x. Return only JSON like {\"x\": <number>}. Equation: 2x + 5 = 13"
 }
]
 }
],
 "reference_answer": {
 "x": 4
 }
}
```

### Limitazioni attuali

- Solo testo: non sono supportati input multimodali (immagini, audio, video)
- Conversazioni a turno singolo: supporta solo messaggi utente singoli (non dialoghi a più turni)
- Formato JSON: i dati di input devono essere in formato JSONL (un oggetto JSON per riga)
- Risultati del modello: la valutazione viene eseguita sui completamenti generati dal modello specificato

## Preparazione della ricetta di valutazione

### Notebook di esempio

Per un esempio completo, consulta [Quaderni di valutazione](#).

### Esempio di configurazione della ricetta

```
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>
```

### Funzioni di ricompensa preimpostate

Due funzioni di ricompensa preimpostate (`prime_codeeprime_math`) sono disponibili come layer Lambda per una facile integrazione con le funzioni RFT Lambda.

## Panoramica di

Queste funzioni preimpostate forniscono funzionalità di valutazione per: out-of-the-box

- `prime_code`— Generazione di codice e valutazione della correttezza
- `prime_math`— Ragionamento matematico e valutazione della risoluzione dei problemi

## Configurazione rapida

1. [Scarica il layer Lambda dalle versioni. nova-custom-eval-sdk](#)

2. Pubblica il layer Lambda utilizzando AWS Command Line Interface (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. Aggiungi il layer alla tua funzione Lambda nella Console di AWS gestione (seleziona il layer `preset-function-layer` dal livello personalizzato e aggiungi anche `AWSSDKPandas-Python 312` per le dipendenze `numpy`).

4. Importa e usa nel tuo codice Lambda:

```
from prime_code import compute_score # For code evaluation
from prime_math import compute_score # For math evaluation
```

## funzione `prime_code`

Valuta le attività di generazione di codice Python eseguendo codice in base a casi di test e misurando la correttezza.

## Esempio di formato del set di dati di input

```
{"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"]}}
```

### Caratteristiche principali

- Estrazione automatica del codice dai blocchi di codice markdown
- Rilevamento delle funzioni e test basati sulle chiamate
- Esecuzione di test case con protezione dal timeout
- Convalida della sintassi e controlli di compilazione
- Segnalazione dettagliata degli errori con traceback

### funzione prime\_math

Valuta le capacità di ragionamento matematico e di risoluzione dei problemi con il supporto della matematica simbolica.

### Formato di input

```
{"messages":[{"role":"user","content":"What is the derivative of x^2 + 3x?."}], "reference_answer":"2*x + 3"}
```

### Caratteristiche principali

- Valutazione matematica simbolica utilizzando SymPy
- Formati di risposta multipli (LaTeX, testo semplice, simbolico)
- Controllo matematico dell'equivalenza
- Normalizzazione e semplificazione delle espressioni

### Requisiti per il formato dei dati

#### Per la valutazione del codice

- Input: matrice di argomenti delle funzioni (tipi propri: numeri interi, stringhe, ecc.)
- Output: matrice di valori restituiti previsti (tipi appropriati: booleani, numeri, ecc.)
- Codice: deve essere in Python con definizioni di funzioni chiare

## Per la valutazione matematica

- Risposta di riferimento: espressione matematica o valore numerico
- Risposta: può essere LaTe X, testo semplice o notazione simbolica
- Equivalenza: verificata simbolicamente, non solo in base alla corrispondenza tra stringhe

## Best practice

- Usa i tipi di dati appropriati nei casi di test (numeri interi contro stringhe, booleani vs «True»)
- Fornisci firme funzionali chiare nei problemi di codice
- Includi casi limite negli input di test (zero, numeri negativi, input vuoti)
- Formatta le espressioni matematiche in modo coerente nelle risposte di riferimento
- Testa la tua funzione di ricompensa con dati di esempio prima dell'implementazione

## Gestione degli errori

Entrambe le funzioni includono una solida gestione degli errori per:

- Errori di compilazione nel codice generato
- Eccezioni di runtime durante l'esecuzione
- Dati di input non validi
- Scenari di timeout per loop infiniti
- Espressioni matematiche non valide

## Creazione della funzione di ricompensa

### Requisiti Lambda ARN

Il tuo Lambda ARN deve seguire questo formato:

```
"arn:aws:lambda:*:*:function:*SageMaker*"
```

Se la Lambda non dispone di questo schema di denominazione, il processo avrà esito negativo con questo errore:

```
[ERROR] Unexpected error: lambda_arn must contain one of: ['SageMaker', 'sagemaker', 'Sagemaker'] when running on SMHP platform (Key: lambda_arn)
```

## Formato di richiesta Lambda

La tua funzione Lambda riceve i dati in questo formato:

```
[
 {
 "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..."
 }
]
 }
],
 "reference_answer": {
 "compliant": "No",
 "explanation": "As an AI developed by Company, I do not have a traditional
security team..."
 }
 }
]
```



 Note

La struttura dei messaggi include l'`contentarray` annidato, corrispondente al formato dei dati di input. L'ultimo messaggio con ruolo `nova_assistant` contiene la risposta generata dal modello.

## Formato di risposta Lambda

La tua funzione Lambda deve restituire dati in questo formato:

```
[
 {
 "id": "sample-001",
 "aggregate_reward_score": 0.75,
 "metrics_list": [
 {
 "name": "accuracy",
 "value": 0.85,
 "type": "Metric"
 },
 {
 "name": "fluency",
 "value": 0.90,
 "type": "Reward"
 }
]
 }
]
```

## Campi di risposta

- `id`— Deve corrispondere all'ID del campione di input
- `aggregate_reward_score`— Punteggio complessivo (in genere da 0,0 a 1,0)
- `metrics_list`— Serie di metriche individuali con:
  - `name`— Identificatore metrico (ad es. «precisione», «fluidità»)
  - `value`— Punteggio metrico (in genere da 0,0 a 1,0)
  - `type`— «Metrico» (per la rendicontazione) o «Premio» (utilizzato nella formazione)

## autorizzazioni IAM

### Autorizzazioni richieste

Il ruolo di SageMaker esecuzione deve disporre delle autorizzazioni per richiamare la funzione Lambda. Aggiungi questa politica al tuo SageMaker ruolo di esecuzione:

```
{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Effect": "Allow",
 "Action": [
 "lambda:InvokeFunction"
],
 "Resource": "arn:aws:lambda:region:account-id:function:function-name"
 }
]
}
```

### Ruolo di esecuzione Lambda

Il ruolo di esecuzione della tua funzione Lambda richiede le autorizzazioni di esecuzione Lambda di base:

```
{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Effect": "Allow",
 "Action": [
 "logs:CreateLogGroup",
 "logs:CreateLogStream",
 "logs:PutLogEvents"
],
 "Resource": "arn:aws:logs:*:*:*"
 }
]
}
```

Se la tua funzione Lambda accede ad altri AWS servizi (ad esempio, S3 per i dati di riferimento, DynamoDB per la registrazione), aggiungi tali autorizzazioni al ruolo di esecuzione Lambda.

## Esecuzione del processo di valutazione

1. Prepara i tuoi dati: formatta i dati di valutazione in base ai requisiti di formato dei dati e carica il file JSONL su S3: `s3://your-bucket/eval-data/eval_data.jsonl`
2. Configura la tua ricetta: aggiorna la ricetta di esempio con la tua configurazione:
  - Imposta `model_name_or_path` la posizione del modello
  - Imposta `lambda_arn` sulla funzione di ricompensa ARN
  - Imposta `output_s3_path` la posizione di uscita desiderata
  - Regola `inference` i parametri secondo necessità

Salva la ricetta con nome `rft_eval_recipe.yaml`

3. Esegui la valutazione: esegui il processo di valutazione utilizzando il taccuino fornito: [Quaderni di valutazione](#)
4. Monitora i progressi: monitora il processo di valutazione tramite:
  - SageMaker Console: controlla lo stato del lavoro e i registri
  - CloudWatch Registri: visualizza i registri di esecuzione dettagliati
  - Lambda Logs: problemi relativi alla funzione di ricompensa di debug

## Comprensione dei risultati della valutazione

### Formato di output

Il processo di valutazione restituisce i risultati nella posizione S3 specificata in formato JSONL. Ogni riga contiene i risultati della valutazione per un campione:

```
{
 "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

L'RFT Evaluation Job Output è identico al formato Lambda Response. Il servizio di valutazione analizza la risposta della funzione Lambda senza modifiche, garantendo la coerenza tra i calcoli delle ricompense e i risultati finali.

## Interpretazione dei risultati

### Punteggio di ricompensa aggregato

- Intervallo: in genere da 0,0 (peggiore) a 1,0 (migliore), ma dipende dall'implementazione
- Scopo: un unico numero che riassume le prestazioni complessive
- Utilizzo: confronta i modelli, monitora i miglioramenti durante l'allenamento

### Metriche individuali

- Tipo di metrica: metriche informative per l'analisi
- Tipo di ricompensa: metriche utilizzate durante la formazione RFT
- Interpretazione: valori più alti in genere indicano prestazioni migliori (a meno che non si progettino metriche inverse)

## Benchmark delle prestazioni

Ciò che costituisce una «buona» prestazione dipende dal caso d'uso:

| Intervallo di punteggio | Interpretazione | Azione                                        |
|-------------------------|-----------------|-----------------------------------------------|
| 0,8 - 1,0               | Eccellente      | Modello pronto per l'implementazione          |
| 0,6 - 0,8               | Buona           | Potrebbero essere utili piccoli miglioramenti |

| Intervallo di punteggio | Interpretazione | Azione                                                   |
|-------------------------|-----------------|----------------------------------------------------------|
| 0,4 - 0,6               | Giusto          | È necessario un miglioramento significativo              |
| 0,0 - 0,4               | Povero          | Rivedi i dati di allenamento e la funzione di ricompensa |

### Important

Queste sono linee guida generali. Definite le vostre soglie in base ai requisiti aziendali, alle prestazioni del modello di base, ai vincoli specifici del dominio e all'analisi costi-benefici dell'ulteriore formazione.

## Risoluzione dei problemi

### Problemi comuni

| Problema              | Causa                                     | Soluzione                                               |
|-----------------------|-------------------------------------------|---------------------------------------------------------|
| Timeout Lambda        | Calcolo complesso dei premi               | Aumentare il timeout Lambda o ottimizzare la funzione   |
| Autorizzazione negata | Autorizzazioni IAM mancanti               | Verifica che SageMaker il ruolo possa richiamare Lambda |
| Punteggi incoerenti   | Funzione di ricompensa non deterministica | Usa seed fissi o logica deterministica                  |
| Risultati mancanti    | Errori Lambda non rilevati                | Aggiungi una gestione completa degli errori in Lambda   |

## Lista di controllo per il debug

- Verifica che i dati di input seguano il formato corretto con array di contenuti annidati

- Verifica che l'ARN Lambda sia corretto e che la funzione sia stata implementata
- Controlla le autorizzazioni IAM per SageMaker → Invocazione Lambda
- Esamina CloudWatch i registri per gli errori Lambda
- Verifica che la risposta Lambda corrisponda al formato previsto

### Best practice

- Inizia in modo semplice: inizia con le funzioni di ricompensa di base e ripeti
- Testa Lambda separatamente: utilizza gli eventi di test Lambda prima della valutazione completa
- Convalida su set di dati di piccole dimensioni: esegui la valutazione sul sottoinsieme prima del set di dati completo
- Controllo della versione: monitora le versioni della funzione di ricompensa insieme alle versioni del modello
- Monitoraggio dei costi: le chiamate Lambda e il tempo di calcolo influiscono sui costi
- Registra in modo esteso: utilizza le istruzioni di stampa in Lambda per il debug
- Imposta i timeout in modo appropriato: equilibrio tra pazienza e costi
- Metriche dei documenti: definisci chiaramente cosa misura ogni metrica

### Fasi successive

Dopo aver completato la valutazione RFT:

- Se i risultati sono soddisfacenti: distribuisce il modello alla produzione
- Se è necessario un miglioramento:
  - Regola la funzione di ricompensa
  - Raccogli più dati di allenamento
  - Modifica gli iperparametri di allenamento
  - Esegui iterazioni di addestramento RFT aggiuntive
- Monitoraggio continuo: rivalutazione periodica con nuovi dati

## Implementazione di funzioni premi

### Panoramica di

La funzione di ricompensa (chiamata anche scorer o grader) è il componente principale che valuta le risposte del modello e fornisce segnali di feedback per l'allenamento. Deve essere implementata come una funzione Lambda che accetta le risposte del modello e restituisce punteggi di ricompensa.

### Formato dell'interfaccia

La tua funzione di ricompensa deve accettare e restituire dati nel seguente formato:

### Esempio di input per la formazione

```
{
 "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..."
 }
}
```

### Esempio di payload per la ricompensa lambda

Il contenitore trasforma automaticamente i dati prima di inviarli alla funzione Lambda tramite:

1. Generazione di un modello di risposta per ogni prompt
2. Aggiungere il turno dell'assistente (risposta generata) all'array dei messaggi
3. Aggiungere un id campo unico per il tracciamento

La tua funzione Lambda riceverà i dati in questo formato trasformato:

```
{
 "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..."
}
}

```

## Contratto Reward Lambda

```

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"
 }
]
 }
"""
```

Campi di input e output

Campi di input

| Campo                | Description                                | Note aggiuntive                                  |
|----------------------|--------------------------------------------|--------------------------------------------------|
| id                   | Identificatore univoco per il campione     | Ripreso in uscita. Formato delle stringhe        |
| messages             | Cronologia chat ordinata in formato OpenAI | Matrice di oggetti di messaggio                  |
| messages [] .role    | Relatore del messaggio                     | Valori comuni: «utente», «assistente», «sistema» |
| messaggi [] .content | Contenuto testuale del messaggio           | Stringa normale                                  |

| Campo      | Description                                                      | Note aggiuntive                                              |
|------------|------------------------------------------------------------------|--------------------------------------------------------------|
| **metadati | Informazioni in formato libero per facilitare la classificazione | Oggetto; campi opzionali trasmessi dai dati di addestramento |

### Campi di output

| Campo                  | Description                                        | Note aggiuntive                                                 |
|------------------------|----------------------------------------------------|-----------------------------------------------------------------|
| id                     | Stesso identificatore del campione di input        | Deve corrispondere all'input                                    |
| aggregate_reward_score | Punteggio complessivo del campione                 | Float (ad esempio, 0,0—1,0 o intervallo definito dall'attività) |
| metrics_list           | Punteggi dei componenti che compongono l'aggregato | Matrice di oggetti metrici                                      |

### Vincoli tecnici

- Limite di timeout: tempo di esecuzione massimo di 15 minuti per chiamata Lambda
- Concorrenza: deve gestire le richieste simultanee `rollout_worker_replicas * 64`
- Affidabilità: deve implementare una corretta gestione degli errori e restituire punteggi validi in modo coerente
- Prestazioni: ottimizzate per un'esecuzione rapida (secondi, non minuti) per consentire un allenamento efficiente

### Best practice

- Riduci al minimo le chiamate API esterne
- Utilizza algoritmi e strutture dati efficienti
- Implementa la logica di ripetizione dei tentativi per guasti transitori
- Memorizza nella cache i calcoli riutilizzabili
- Esegui test approfonditi prima dell'addestramento per garantire un'esecuzione priva di bug

## Utilizzo di funzioni di ricompensa personalizzate

Implementa funzioni di ricompensa personalizzate quando disponi di criteri di valutazione specifici per attività:

- Definisci i criteri di valutazione: stabilisci cosa rappresenta una buona risposta per il tuo compito
- Implementa la funzione Lambda: crea una funzione Lambda seguendo il formato dell'interfaccia
- Esegui il test a livello locale: convalida la funzione e restituisce punteggi corretti per gli input di esempio
- Implementa su AWS: distribuisce la tua Lambda e annota l'ARN
- Configura ricetta: aggiungi l'ARN Lambda al campo della ricetta `reward_lambda_arn`
- Esegui test con set di dati di piccole dimensioni: esegui RFT con un numero minimo di dati per verificare l'integrazione

## autorizzazioni IAM

### Autorizzazioni richieste

Il ruolo di SageMaker esecuzione deve disporre delle autorizzazioni per richiamare la funzione Lambda. Aggiungi questa politica al tuo SageMaker ruolo di esecuzione:

```
{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Effect": "Allow",
 "Action": [
 "lambda:InvokeFunction"
],
 "Resource": "arn:aws:lambda:region:account-id:function:function-name"
 }
]
}
```

## Ruolo di esecuzione Lambda

Il ruolo di esecuzione della tua funzione Lambda richiede le autorizzazioni di esecuzione Lambda di base:

```
{
```

```
"Version": "2012-10-17",
"Statement": [
 {
 "Effect": "Allow",
 "Action": [
 "logs:CreateLogGroup",
 "logs:CreateLogStream",
 "logs:PutLogEvents"
],
 "Resource": "arn:aws:logs:*:*:*"
 }
]
```

Autorizzazioni aggiuntive: se la funzione Lambda accede ad AWS altri servizi (ad esempio, S3 per i dati di riferimento, DynamoDB per la registrazione), aggiungi tali autorizzazioni al ruolo di esecuzione Lambda.

### Esempio: funzione di ricompensa LLM As a Judge

Questo esempio dimostra l'utilizzo dei modelli Amazon Bedrock come giudici per valutare le risposte del modello confrontandole con le risposte di riferimento. Questo modello Lambda fornisce ai clienti un framework per implementare chiamate ad Amazon Bedrock per richieste di inferenza per elaborare le valutazioni degli arbitri. La funzione Lambda mantiene lo stesso input/output contratto delle altre funzioni di ricompensa.

### Implementazione

Questa funzione Lambda implementa un processo di valutazione in due fasi: `lambda_handler` estrae le risposte del modello e le risposte di riferimento dai campioni in entrata, quindi la funzione `lambda_graded` chiama Amazon Bedrock per valutare la somiglianza semantica tra di esse. L'implementazione include una solida gestione degli errori con tentativi automatici in caso di errori temporanei e supporta formati di risposta di riferimento flessibili (formati di stringhe e dizionari strutturati).

### Dettagli di implementazione:

- **Retry Logic:** implementa il backoff esponenziale (1s, 2s, 4s) per limitare le eccezioni per gestire i limiti di velocità dell'API Bedrock
- **Gestione degli errori:** restituisce un punteggio di 0,0 per le valutazioni non riuscite anziché sollevare eccezioni

- Punteggio deterministico: utilizza la temperatura = 0,0 per garantire punteggi coerenti tra le valutazioni
- Formato di riferimento flessibile: gestisce automaticamente sia le risposte di riferimento a stringhe che quelle del dizionario
- Fissaggio del punteggio: assicura che tutti i punteggi rientrino nell'intervallo valido [0.0, 1.0]
- Indipendente dal modello: modifica JUDGE\_MODEL\_ID per utilizzare qualsiasi modello Amazon Bedrock (Nova, Llama, Mistral, ecc.)

```
"""
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
 field
 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)})}

```

## Formato di input

La Lambda riceve lo stesso formato di input delle altre funzioni di ricompensa:

```

{
 "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"
}
```

## Formato di output

```
{
 "id": "sample-001",
 "aggregate_reward_score": 0.85,
 "metrics_list": [
 {
 "name": "similarity_score",
 "value": 0.85,
 "type": "Metric"
 }
]
}
```

## Considerazioni sull'implementazione

Potrebbe inoltre essere necessario modificare il modello di prompt e i parametri di inferenza in base alle funzionalità del modello scelto e al formato API.

- **Autorizzazioni IAM:** il ruolo di esecuzione Lambda deve `bedrock:InvokeModel` disporre dell'autorizzazione per il modello scelto
- **Timeout:** imposta il timeout Lambda su almeno 60 secondi per adattarsi alla latenza e ai nuovi tentativi dell'API Bedrock
- **Regione:** esegui la distribuzione in una regione in cui è disponibile il modello Bedrock scelto



- Costo: monitora l'utilizzo dell'API Bedrock poiché ogni valutazione effettua una chiamata API per campione
- Produttività: per le valutazioni su larga scala, richiedi un aumento delle quote Bedrock per evitare limitazioni

### Aumento della produttività di Bedrock

Se riscontri un rallentamento durante la valutazione, aumenta le quote del modello Bedrock:

- Vai alla console AWS Service Quotas
- Cerca «Bedrock» e seleziona la tua regione
- Trova la quota per il modello scelto (ad esempio, «Invocazioni al minuto per Claude 3.5 Sonnet»)
- Fai clic su «Richiedi aumento della quota» e specifica la produttività desiderata
- Fornisci una giustificazione per l'aumento (ad esempio, «carico di lavoro di valutazione RFT»)

La logica di ripetizione integrata in Lambda gestisce le limitazioni occasionali, ma valutazioni sostenute ad alto volume richiedono aumenti di quota adeguati.

Policy IAM richiesta:

```
{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Effect": "Allow",
 "Action": [
 "bedrock:InvokeModel"
],
 "Resource": "arn:aws:bedrock:*::foundation-model/*"
 }
]
}
```

## Addestramento iterativo

La formazione iterativa è un approccio sistematico per perfezionare i modelli attraverso più cicli di formazione, in cui ogni round si basa sul checkpoint precedente affrontando i punti deboli specifici scoperti durante la valutazione. Questo metodo consente miglioramenti mirati delle prestazioni del

modello incorporando esempi curati che affrontano le modalità di errore, adattandosi ai requisiti in evoluzione e convalidando i miglioramenti in modo incrementale anziché impegnarsi in un unico lungo periodo di formazione. Il processo segue in genere modelli come SFT (Supervised Fine-Tuning) seguito da RFT (Reward-based Fine-Tuning), con checkpoint archiviati in bucket S3 escrow AWS gestiti a cui è possibile fare riferimento per le successive iterazioni di addestramento, mantenendo al contempo la coerenza nel tipo di modello e nella tecnica di addestramento in tutta la pipeline.

Per ulteriori informazioni, consulta [???.](#)

## Personalizzazione di Amazon Nova su SageMaker HyperPod

Puoi personalizzare i modelli Amazon Nova, inclusi i modelli Amazon Nova 2.0 migliorati, utilizzando [le ricette di Amazon Nova](#) e addestrarli su Hyperpod. Una ricetta è un file di configurazione YAML che fornisce dettagli all' SageMaker IA su come eseguire il processo di personalizzazione del modello. SageMaker HyperPod supporta due tipi di servizi: Forge e non-Forge.

Hyperpod offre elaborazione ad alte prestazioni con istanze GPU ottimizzate e storage FSx Amazon for Lustre, un monitoraggio affidabile attraverso l'integrazione con strumenti TensorBoard come la gestione flessibile dei checkpoint per il miglioramento iterativo, la distribuzione senza interruzioni su Amazon Bedrock per l'inferenza e una formazione distribuita efficiente e scalabile a più nodi, il tutto in sinergia per fornire alle organizzazioni un ambiente sicuro, performante e flessibile per personalizzare i modelli Amazon Nova in base ai loro requisiti aziendali specifici.

La personalizzazione di Amazon Nova su SageMaker HyperPod archivia gli artefatti del modello, inclusi i checkpoint del modello, in un bucket Amazon S3 gestito dal servizio. Gli artefatti nel bucket gestito dal servizio sono crittografati con chiavi gestite dall'intelligenza artificiale. SageMaker AWS KMS I bucket Amazon S3 gestiti dal servizio attualmente non supportano la crittografia dei dati tramite chiavi KMS gestite dal cliente. È possibile utilizzare questa posizione di checkpoint per processi di valutazione o per l'inferenza Amazon Bedrock.

I prezzi standard possono essere applicati per le istanze di calcolo, lo storage Amazon S3 e Lustre. FSx Per i dettagli sui prezzi, consulta i [prezzi di Hyperpod](#), i [prezzi di Amazon S3 FSx](#) e i [prezzi di Lustre](#).

## Requisiti di calcolo per i modelli Amazon Nova 2

Le tabelle seguenti riassumono i requisiti di calcolo SageMaker HyperPod e la formazione per i lavori di formazione sull' SageMaker intelligenza artificiale per i modelli Amazon Nova 2.

## Requisiti di formazione per Nova 2

| Tecnica di allenamento                                  | Istanze minime | Tipo di istanza | Numero di GPU | Note                                                                  | Modelli supportati |
|---------------------------------------------------------|----------------|-----------------|---------------|-----------------------------------------------------------------------|--------------------|
| SFT (LoRa)                                              | 4              | P5,48 x grande  | 16            | Regolazione di precisione efficiente dal punto di vista dei parametri | Nova 2 Lite        |
| SFT (rango completo)                                    | 4              | P5,48 x grande  | 32            | Ottimizzazione completa del modello                                   | Nova 2 Lite        |
| RFT su SageMaker Training Jobs (LoRa)                   | 2              | P5,48 x grande  | 16            | Funzioni di ricompensa personalizzate nel tuo ambiente AWS            | Nova 2 Lite        |
| RFT sui lavori SageMaker di formazione (rango completo) | 4              | P5,48 x grande  | 32            | Lunghezza del contesto 32K                                            | Nova 2 Lite        |
| RFT attivo SageMaker HyperPod                           | 8              | P5.48 x grande  | 64            | Lunghezza predefinita del contesto 8192                               | Nova 2 Lite        |
| CPT                                                     | 4              | P5,48 x grande  | 16            | Elabora circa 400 milioni di token per istanza al giorno              | Nova 2 Lite        |

Per ottimizzare i flussi di lavoro di personalizzazione dei modelli Amazon Nova su Hyperpod, segui queste best practice consigliate per una formazione efficiente, una gestione delle risorse e un'implementazione efficace del modello.

## Best practice per la personalizzazione di Amazon Nova

### Panoramica di

Questa sezione fornisce una panoramica delle tecniche di personalizzazione e ti aiuta a scegliere l'approccio migliore per le tue esigenze e i dati disponibili.

### Due fasi della formazione LLM

La formazione su modello linguistico di grandi dimensioni consiste in due fasi principali: pre-formazione e post-formazione. Durante la formazione preliminare, il modello elabora i token di testo non elaborato e li ottimizza per la previsione del token successivo. Questo processo crea un completatore di modelli che assorbe la sintassi, la semantica, i fatti e gli schemi di ragionamento dal web e dal testo curato. Tuttavia, il modello pre-addestrato non comprende le istruzioni, gli obiettivi dell'utente o il comportamento appropriato al contesto. Continua il testo in qualsiasi stile si adatti alla distribuzione della formazione. Un modello già addestrato si completa automaticamente anziché seguire le istruzioni, produce una formattazione incoerente e può rispecchiare pregiudizi indesiderati o contenuti non sicuri presenti nei dati di addestramento. La formazione preliminare rafforza la competenza generale, non l'utilità delle attività.

Dopo l'allenamento, il Pattern Completer si trasforma in un utile assistente. Si eseguono diversi cicli di Supervised Fine-Tuning (SFT) per insegnare al modello a seguire le istruzioni, aderire a schemi e politiche, chiamare strumenti e produrre risultati affidabili imitando dimostrazioni di alta qualità. Questo allineamento insegna al modello a rispondere alle istruzioni come attività anziché come testo per continuare. Si applica quindi il Reinforcement Fine-Tuning (RFT) per ottimizzare il comportamento utilizzando feedback misurabili (ad esempio verificatori o altro), bilanciando compromessi come la precisione rispetto alla brevità, la sicurezza rispetto alla copertura o il LLM-as-a-judge ragionamento in più fasi in base ai vincoli. In pratica, si alternano SFT e RFT in cicli per modellare il modello pre-addestrato in un sistema affidabile e allineato alle politiche che esegue attività complesse in modo coerente.

### Scegliete il giusto approccio di personalizzazione

In questa sezione tratteremo le strategie di personalizzazione post-formazione: RFT e SFT.

## Ottimizzazione precisa dei rinforzi (RFT)

La messa a punto del rinforzo migliora le prestazioni del modello attraverso segnali di feedback (punteggi misurabili o premi che indicano la qualità della risposta) anziché la supervisione diretta con risposte esatte e corrette. A differenza della tradizionale ottimizzazione supervisionata che apprende dalle coppie di input-output, RFT utilizza le funzioni di ricompensa per valutare le risposte del modello e ottimizza iterativamente il modello per massimizzare tali ricompense. Questo approccio è ideale per le attività in cui è difficile definire l'output esatto e corretto, ma è possibile misurare in modo affidabile la qualità della risposta. RFT consente ai modelli di apprendere comportamenti e preferenze complessi attraverso prove e feedback, il che lo rende ideale per applicazioni che richiedono un processo decisionale articolato, una risoluzione creativa dei problemi o il rispetto di criteri di qualità specifici che è possibile valutare programmaticamente. Ad esempio, rispondere a domande legali complesse è un caso d'uso ideale per RFT, perché si desidera insegnare al modello come ragionare meglio per rispondere alle domande in modo più accurato.

### Come funziona

Nella messa a punto dei rinforzi, si parte da una linea di base basata sulle istruzioni e si tratta ogni richiesta come un piccolo torneo. In base a un determinato contributo, si campionano alcune risposte dei candidati tratte dal modello, si assegna un punteggio a ciascuna di esse con la funzione di ricompensa, quindi le si classifica all'interno di quel gruppo. La fase di aggiornamento spinge il modello a rendere più propensi i candidati con punteggi più alti la prossima volta e meno quelli con punteggi più bassi, mentre un stay-close-to-baseline vincolo impedisce che il comportamento diventi prolosso o sfruttatore. Ripeti questo ciclo su molte richieste, aggiornando i casi più complessi, rendendo più rigorosi i verificatori o giudicando le rubriche quando vedi degli exploit e monitorando continuamente le metriche relative alle attività.

### Quando usare RFT

Le attività che traggono i maggiori vantaggi da RFT hanno diverse caratteristiche in comune. Offrono segnali di successo misurabili anche quando è difficile specificare un singolo output corretto. Ammettono crediti parziali o una qualità graduata, in modo da poter classificare le risposte migliori rispetto a quelle peggiori in un prompt o utilizzando una funzione di ricompensa. Esse implicano molteplici obiettivi che devono essere bilanciati (ad esempio precisione e brevità, chiarezza, sicurezza o costi). Richiedono il rispetto di vincoli espliciti che è possibile verificare a livello di codice. Operano in ambienti mediati da strumenti o basati sull'ambiente in cui i risultati sono osservabili (successo o fallimento, latenza, utilizzo delle risorse). Si verificano in regimi in cui la raccolta di obiettivi prioritari è costosa, ma il feedback automatizzato o basato sulle rubriche è abbondante. RFT funziona al meglio quando è possibile trasformare la qualità in uno scalare o in una classifica

affidabile e se si desidera che il modello amplifichi preferenzialmente i comportamenti che ottengono punteggi più elevati senza bisogno di obiettivi etichettati esaustivi.

Prendi in considerazione altri metodi quando:

- Disponete di numerose e affidabili coppie di ingresso/uscita etichettate: utilizzate SFT
- La lacuna principale è la conoscenza o il gergo: utilizzate la generazione aumentata di recupero (RAG)
- Il segnale di ricompensa è rumoroso o inaffidabile e non è possibile correggerlo con rubriche o pedine migliori: stabilizzalo prima di RFT

Quando non usare RFT

Evita l'RFT in queste situazioni:

- È possibile produrre coppie ingresso-uscita etichettate affidabili a basso costo (SFT è più semplice, economico e stabile)
- Il divario è la conoscenza o il gergo piuttosto che il comportamento (usa RAG)
- Il tuo segnale di ricompensa è rumoroso, scarso, facile da usare, costoso o lento da calcolare (correggi prima il valutatore)
- Le prestazioni di base sono prossime allo zero (avviate con SFT prima di ottimizzare le preferenze)
- L'attività ha schemi deterministici, una formattazione rigorosa o un'unica risposta corretta (la SFT o la convalida basata su regole funzionano meglio)
- I budget limitati in termini di latenza o costi non sono in grado di assorbire i costi aggiuntivi di campionamento o esplorazione richiesti da RFT
- I vincoli relativi alla sicurezza o alle politiche non sono specificati in modo preciso e applicabili nella ricompensa

Se riesci a indicare «la risposta giusta», usa SFT. Se hai bisogno di nuove conoscenze, usa RAG. Usa RFT solo dopo avere una base solida e una funzione di ricompensa robusta e veloce. hard-to-exploit

Fine-tuning supervisionato (SFT)

La messa a punto supervisionata addestra l'LLM su un set di dati di coppie input-output etichettate dall'uomo per ogni attività. Fornite esempi di richieste (domande, istruzioni e così via) con le risposte corrette o desiderate e continuate ad addestrare il modello sulla base di questi esempi. Il modello

regola i propri pesi per ridurre al minimo una perdita supervisionata (in genere entropia incrociata tra le previsioni e i token di output target). Questa è la stessa formazione utilizzata nella maggior parte delle attività di apprendimento automatico supervisionate, applicata per specializzare un LLM.

La SFT modifica il comportamento, non la conoscenza. Non insegna al modello nuovi fatti o gerghi che non aveva appreso durante il pre-allenamento. Insegna al modello come rispondere, non cosa sapere. Se hai bisogno di nuove conoscenze di dominio (come la terminologia interna), usa la generazione aumentata di recupero (RAG) per fornire quel contesto al momento dell'inferenza. SFT aggiunge quindi in primo piano il comportamento desiderato di seguire le istruzioni.

## Come funziona

SFT ottimizza LLM riducendo al minimo la perdita media di entropia incrociata sui token di risposta, trattando i token prompt come contesto e mascherandoli dalla perdita. Il modello interiorizza lo stile, la struttura e le regole decisionali dell'obiettivo, imparando a generare il completamento corretto per ogni prompt. Ad esempio, per classificare i documenti in categorie personalizzate, si ottimizza il modello con istruzioni (il testo del documento) e completamenti etichettati (le etichette delle categorie). Ci si allena su queste coppie finché il modello non restituisce l'etichetta corretta per ogni prompt con alta probabilità.

È possibile eseguire SFT con poche centinaia di esempi e scalare fino a poche centinaia di migliaia. I campioni SFT devono essere di alta qualità e allineati direttamente al comportamento del modello desiderato.

## Quando usare SFT

Usa SFT quando hai un'attività ben definita con risultati chiari e desiderati. Se potete dichiarare esplicitamente «Dato l'input X, l'output corretto è Y» e raccogliere esempi di tali mappature, la regolazione fine supervisionata è una buona scelta. SFT eccelle in questi scenari:

- Attività di classificazione strutturate o complesse: classificate documenti o contratti interni in molte categorie personalizzate. Con SFT, il modello impara queste categorie specifiche meglio di quanto lo faccia da solo.
- Attività di risposta a domande o di trasformazione con risposte note: perfeziona un modello per rispondere alle domande della knowledge base di un'azienda o converti i dati tra formati in cui ogni input ha una risposta corretta.
- Formattazione e coerenza stilistica: addestrate il modello a rispondere sempre in un determinato formato o tono perfezionando gli esempi del formato o del tono corretti. Ad esempio, la formazione sulle coppie di risposte rapide che dimostrano la voce di un marchio specifica insegna al modello a

generare risultati con quello stile. Il comportamento che segue le istruzioni viene spesso insegnato inizialmente tramite SFT sulla base di esempi curati di buon comportamento degli assistenti.

L'SFT è il modo più diretto per insegnare a un LLM una nuova abilità o un nuovo comportamento quando è possibile specificare quale sia il comportamento giusto. Utilizza la comprensione linguistica esistente del modello e la concentra sul tuo compito. Utilizzate SFT quando volete che il modello faccia una cosa specifica e avete o potete creare un set di dati di esempi.

Utilizzate SFT quando potete assemblare coppie di prompt e response di alta qualità che rispecchiano fedelmente il comportamento desiderato. Si adatta a compiti con obiettivi chiari o formati deterministici come schemi, chiamate a funzioni o strumenti e risposte strutturate in cui l'imitazione è un segnale di allenamento appropriato. L'obiettivo è modellare il comportamento: insegnare al modello a trattare i prompt come attività, seguire le istruzioni, adottare politiche di tono e rifiuto e produrre una formattazione coerente. Pianifica almeno centinaia di dimostrazioni, con la qualità, la coerenza e la deduplicazione dei dati più importanti del volume grezzo. Per un aggiornamento semplice ed economico, utilizza metodi efficienti in termini di parametri come Low-Rank Adaptation per addestrare piccoli adattatori lasciando intatta la maggior parte della spina dorsale.

## Quando non usare SFT

Non utilizzare SFT quando il divario è la conoscenza piuttosto che il comportamento. Non insegna al modello nuovi fatti, gergo o eventi recenti. In questi casi, utilizza la generazione aumentata con recupero per portare conoscenze esterne all'inferenza. Evita l'SFT quando puoi misurare la qualità ma non riesci a etichettare una sola risposta corretta. Usa la messa a punto dei rinforzi con ricompense verificabili oppure una per ottimizzare direttamente tali ricompense. LLM-as-a-judge Se le tue esigenze o i tuoi contenuti cambiano frequentemente, affidati al recupero e all'uso degli strumenti piuttosto che alla riqualificazione del modello.

## Argomenti

- [SDK Nova Forge](#)
- [Creazione di un cluster SageMaker HyperPod EKS con gruppo di istanze ristrette \(RIG\)](#)
- [Guida ai comandi SageMaker HyperPod essenziali di Amazon](#)
- [Accesso e configurazione di Nova Forge per](#)
- [Formazione per i modelli Amazon Nova](#)
- [Valutazione di un modello addestrato](#)
- [Monitoraggio dei lavori con HyperPod MLflow](#)



## SDK Nova Forge

L'SDK Amazon Nova Forge è un SDK Python completo che fornisce un'interfaccia programmatica unificata per l'intero ciclo di vita di personalizzazione del modello Amazon Amazon Nova. L'SDK semplifica la personalizzazione dei modelli offrendo un'unica API coerente per la formazione, la valutazione, il monitoraggio, la distribuzione e l'inferenza su piattaforme Amazon SageMaker e Amazon Bedrock.

Per ulteriori informazioni, consulta [SDK Nova Forge](#).

## Creazione di un cluster SageMaker HyperPod EKS con gruppo di istanze ristrette (RIG)

Per personalizzare un modello su Hyperpod, è necessario configurare l'infrastruttura necessaria. Per i dettagli sulla configurazione di un cluster SageMaker HyperPod EKS con un gruppo di istanze ristrette (RIG), visitate il [workshop](#), che fornisce una guida dettagliata del processo di configurazione.

## Guida ai comandi SageMaker HyperPod essenziali di Amazon

Amazon SageMaker HyperPod offre ampie funzionalità da riga di comando per la gestione dei flussi di lavoro di formazione. Questa guida descrive i comandi essenziali per le operazioni più comuni, dalla connessione al cluster al monitoraggio dell'avanzamento dei lavori.

### Prerequisiti

Prima di utilizzare questi comandi, assicuratevi di aver completato la seguente configurazione:

- SageMaker HyperPod cluster con RIG creato (tipicamente in us-east-1)
- Output: bucket Amazon S3 creato per gli artefatti di addestramento
- Ruoli IAM configurati con autorizzazioni appropriate
- Dati di allenamento caricati nel formato JSONL corretto
- FSx per Lustre sync completata (verifica nei log del cluster al primo processo)

### Argomenti

- [Installazione della CLI di ricetta](#)
- [Connessione al cluster](#)
- [Avvio di un lavoro di formazione](#)

- [Verifica dello stato del lavoro](#)
- [Monitoraggio dei registri dei lavori](#)
- [Elenco delle offerte di lavoro attive](#)
- [Annullare un lavoro](#)
- [Esecuzione di un processo di valutazione](#)
- [Problemi comuni](#)

## Installazione della CLI di ricetta

Vai alla directory principale del tuo repository di ricette prima di eseguire il comando di installazione.

Usa il repository Hyperpodrecipes se utilizzi tecniche di personalizzazione Non Forge, per la personalizzazione basata su Forge fai riferimento al repository di ricette specifico di forge.

Esegui i seguenti comandi per installare la SageMaker HyperPod CLI:

### Note

Assicurati di non trovarti in un ambiente conda /anaconda/miniconda attivo o in un altro ambiente virtuale

Se lo sei, esci dall'ambiente usando:

- `conda deactivate` per ambienti conda/anaconda/miniconda
- `deactivate` per ambienti virtuali Python

Se utilizzi una tecnica di personalizzazione Non Forge, scaricala sagemaker-hyperpod-recipes come mostrato di seguito:

```
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
```

Se sei un abbonato a Forge, dovresti scaricare le ricette utilizzando la procedura indicata di seguito.

```
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

Per utilizzare un [nuovo ambiente virtuale prima dell'esecuzione](#) `pip install -e .`, esegui:

- `python -m venv nova_forge`
- `source nova_forge/bin/activate`
- La riga di comando verrà ora visualizzata (`nova_forge`) all'inizio del prompt
- Ciò garantisce che non vi siano dipendenze concorrenti quando si utilizza la CLI.

Scopo: perché lo facciamo? `pip install -e .`

Questo comando installa la SageMaker HyperPod CLI in modalità modificabile, che consente di utilizzare ricette aggiornate senza reinstallarle ogni volta. Consente inoltre di aggiungere nuove ricette che la CLI può selezionare automaticamente.

## Connessione al cluster

Connect la SageMaker HyperPod CLI al cluster prima di eseguire qualsiasi job:

```
export AWS_REGION=us-east-1 && SageMaker HyperPod connect-cluster --cluster-name
<your-cluster-name> --region us-east-1
```

### Important

Questo comando crea un file di contesto (/tmp/hyperpod\_context.json) richiesto dai comandi successivi. Se visualizzi un errore relativo a questo file non trovato, esegui nuovamente il comando connect.

Suggerimento: puoi configurare ulteriormente il cluster in modo che utilizzi sempre lo spazio dei kubeflow nomi aggiungendo l'--namespace kubeflowargomento al comando come segue:

```
export AWS_REGION=us-east-1 && \
hyperpod connect-cluster \
--cluster-name <your-cluster-name> \
--region us-east-1 \
--namespace kubeflow
```

Ciò consente di risparmiare la fatica di aggiungere il comando -n kubeflow in ogni comando quando si interagisce con i job.

## Avvio di un lavoro di formazione

### Note

Se state eseguendo dei PPO/RFT lavori, assicuratevi di aggiungere le impostazioni del selettore di etichette src/hyperpod\_cli/sagemaker\_hyperpod\_recipes/recipes\_collection/cluster/k8s.yaml in modo che tutti i pod siano programmati sullo stesso nodo.

```
label_selector:
 required:
 sagemaker.amazonaws.com/instance-group-name:
 - <rig_group>
```

Avvia un processo di formazione utilizzando una ricetta con sostituzioni facoltative dei parametri:

```
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"
}'
```

## Output previsto:

```
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>"
}
```

## Verifica dello stato del lavoro

Monitora i tuoi lavori in esecuzione usando kubectl:

```
kubectl get pods -o wide -w -n kubeflow | (head -n1 ; grep <your-job-name>)
```

## Comprensione degli stati dei pod

La tabella seguente illustra gli stati comuni dei pod:

| Status                          | Description                                                                                                     |
|---------------------------------|-----------------------------------------------------------------------------------------------------------------|
| Pending                         | Pod accettato ma non ancora programmato su un nodo o in attesa che le immagini del contenitore vengano estratte |
| Running                         | Pod associato a un nodo con almeno un contenitore in esecuzione o in fase di avvio                              |
| Succeeded                       | Tutti i contenitori sono stati completati correttamente e non verranno riavviati                                |
| Failed                          | Tutti i contenitori sono terminati e almeno uno è terminato con un errore                                       |
| Unknown                         | Lo stato del pod non può essere determinato (in genere a causa di problemi di comunicazione tra i nodi)         |
| CrashLoopBackOff                | Errore ripetuto del container; Kubernetes si ritira dai tentativi di riavvio                                    |
| ImagePullBackOff / ErrImagePull | Impossibile estrarre l'immagine del contenitore dal registro                                                    |
| OOMKilled                       | Contenitore terminato per superamento dei limiti di memoria                                                     |
| Completed                       | Job o Pod completato correttamente (completamento del lavoro in batch)                                          |

**i** Tip

Usa il `-w` flag per guardare gli aggiornamenti sullo stato del pod in tempo reale. Premi `Ctrl +C` per interrompere la visione.

## Monitoraggio dei registri dei lavori

È possibile visualizzare i registri in tre modi:

### Usando CloudWatch

I tuoi log sono disponibili nel tuo AWS account che contiene Hyperpodcluster in. CloudWatch Per visualizzarli nel browser, vai alla CloudWatch home page del tuo account e cerca il nome del cluster. Ad esempio, se il cluster fosse chiamato, `my-hyperpod-rig` il gruppo di log avrebbe il prefisso:

- Gruppo di log: `/aws/sagemaker/Clusters/my-hyperpod-rig/{UUID}`
- Una volta entrato nel gruppo di log, puoi trovare il tuo registro specifico utilizzando l'ID dell'istanza del nodo, ad esempio `-hyperpod-i-00b3d8a1bf25714e4`.
  - `i-00b3d8a1bf25714e4` rappresenta il nome del computer Hyperpodfriendly su cui è in esecuzione il processo di formazione. Ricordiamo come nell'**`kubect1 get pods -o wide -w -n kubeflow | (head -n1 ; grep my-cpt-run)`** output del comando precedente abbiamo catturato una colonna chiamata NODE.
  - L'esecuzione del nodo «master» in questo caso era in esecuzione su hyperpod `i-00b3d8a1bf25714e4` e quindi useremo quella stringa per selezionare il gruppo di log da visualizzare. Seleziona quello che dice `SagemakerHyperPodTrainingJob/rig-group/[NODE]`

### Utilizzo di CloudWatch Insights

Se hai il nome del tuo lavoro a portata di mano e non desideri seguire tutti i passaggi precedenti, puoi semplicemente interrogare tutti i log sottostanti `/aws/sagemaker/Clusters/my-hyperpod-rig/{UUID}` per trovare il registro individuale.

CPT:

```
fields @timestamp, @message, @logStream, @log
```

```
| filter @message like /(?!i)Starting CPT Job/
| sort @timestamp desc
| limit 100
```

Per completare il lavoro, sostituire con `Starting CPT Job` `CPT Job completed`

Quindi puoi fare clic sui risultati e scegliere quello che dice «Epoch 0» poiché sarà il tuo nodo principale.

Usando il AWS CLI

Puoi scegliere di tracciare i tuoi log utilizzando la AWS CLI. Prima di farlo, controlla che la tua versione di aws cli utilizzi. `aws --version` Si consiglia inoltre di utilizzare questo script di utilità che aiuta a tracciare i log in tempo reale nel terminale

per V1:

```
aws logs get-log-events \
--log-group-name /aws/sagemaker/YourLogGroupName \
--log-stream-name YourLogStream \
--start-from-head | jq -r '.events[].message'
```

per V2:

```
aws logs tail /aws/sagemaker/YourLogGroupName \
--log-stream-name YourLogStream \
--since 10m \
--follow
```

## Elenco delle offerte di lavoro attive

Visualizza tutti i lavori in esecuzione nel tuo cluster:

```
hyperpod list-jobs -n kubeflow
```

Output di esempio:

```
{
 "jobs": [
```



```
{
 "Name": "test-run-nhgza",
 "Namespace": "kubeflow",
 "CreationTime": "2025-10-29T16:50:57Z",
 "State": "Running"
}
```

## Annullare un lavoro

Interrompi un processo in esecuzione in qualsiasi momento:

```
hyperpod cancel-job --job-name <job-name> -n kubeflow
```

Trovare il nome del lavoro

Opzione 1: Dalla tua ricetta

Il nome del lavoro è specificato nel `run` blocco della ricetta:

```
run:
 name: "my-test-run" # This is your job name
 model_type: "amazon.nova-micro-v1:0:128k"
 ...
```

Opzione 2: dal comando `list-jobs`

Usa `hyperpod list-jobs -n kubeflow` e copia il `Name` campo dall'output.

## Esecuzione di un processo di valutazione

Valuta un modello addestrato o un modello base utilizzando una ricetta di valutazione.

### Prerequisiti

Prima di eseguire i lavori di valutazione, assicuratevi di disporre di:

- Controlla l'URI di Amazon S3 dal file `manifest.json` del tuo processo di formazione (per i modelli addestrati)

- Set di dati di valutazione caricato su Amazon S3 nel formato corretto
- Percorso di output Amazon S3 per i risultati della valutazione

## Comando

Esegui il comando seguente per avviare un processo di valutazione:

```
hyperpod start-job -n kubeflow \
 --recipe evaluation/nova/nova_2_0/nova_lite/
nova_lite_2_0_p5_48x1_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"
 }'
```

## Descrizioni dei parametri:

- `recipes.run.name`: nome univoco per il lavoro di valutazione
- `recipes.run.model_name_or_path`: URI Amazon S3 da `manifest.json` o percorso del modello di base (ad es.) `nova-micro/prod`
- `recipes.run.output_s3_path`: posizione Amazon S3 per i risultati della valutazione
- `recipes.run.data_s3_path`: posizione Amazon S3 del set di dati di valutazione

## Suggerimenti:

- Ricette specifiche per ogni modello: ogni modello di taglia (micro, lite, pro) ha una propria ricetta di valutazione
- Valutazione del modello di base: utilizza i percorsi del modello di base (ad esempio `nova-micro/prod`) anziché il checkpoint URIs per valutare i modelli di base

## Formato dei dati di valutazione

### Formato di input (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"
}
```

### Formato di output:

```
{
 "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'}"
}
```

### Descrizioni dei campi:

- **prompt:** input formattato inviato al modello
- **inference:** risposta generata dal modello
- **gold:** Risposta corretta prevista dal set di dati di input
- **metadata:** metadati opzionali trasmessi dall'input

### Problemi comuni

- **ModuleNotFoundError:** No module named 'nemo\_launcher', potresti dover aggiungere `nemo_launcher` al tuo percorso Python in base a dove `hyperpod_cli` è installato. Comando di esempio:

```
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' indica che non hai eseguito il comando `hyperpod connect cluster`.

- Se non vedi il tuo lavoro pianificato, ricontrolla se l'output della tua SageMaker HyperPod CLI contiene questa sezione con i nomi dei lavori e altri metadati. In caso contrario, reinstalla Helm Chart eseguendo:

```
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
```

## Accesso e configurazione di Nova Forge per

Per configurare Amazon Nova Forge per l'utilizzo con Jobs, devi:

- Abbonati ad Amazon Nova Forge
- Configura un cluster

### Argomenti

- [Abbonati ad Amazon Nova Forge](#)
- [Configura l'infrastruttura](#)
- [Al responsabile](#)

## Abbonati ad Amazon Nova Forge

Per accedere alle funzionalità di Amazon Nova Forge, completa i seguenti passaggi:

1. Verifica l'accesso dell'amministratore all' AWS account.
2. Passa alla console SageMaker AI e [richiedi l'accesso ad Amazon Nova Forge](#).
3. Attendi che il team di Amazon Nova invii un'e-mail di conferma dopo l'approvazione della richiesta di abbonamento.
4. Etichetta il tuo ruolo di esecuzione con il `forge-subscription` tag. Questo tag è necessario per accedere alle funzionalità e ai checkpoint di Amazon Nova Forge. Aggiungi il seguente tag al tuo ruolo di esecuzione:
  - Chiave: `forge-subscription`
  - Valore: `true`

 Note

Le funzionalità standard di Amazon Nova rimangono disponibili senza un abbonamento a Forge. Amazon Nova Forge è progettato per creare modelli di frontiera personalizzati con controllo e flessibilità in tutte le fasi di formazione dei modelli.

## Configura l'infrastruttura

Una volta approvato l'abbonamento ad Amazon Nova Forge, configura l'infrastruttura necessaria per utilizzare le funzionalità abilitate per Forge. [Per istruzioni dettagliate sulla creazione di un cluster EKS con un gruppo di istanze ristrette \(RIG\), segui le istruzioni del workshop.](#)

## Al responsabile

Impostazioni di moderazione dei contenuti: i clienti di Amazon Nova Forge hanno accesso a Impostazioni di moderazione dei contenuti personalizzabili (CCMS) per i modelli Amazon Nova Lite 1.0 e Pro 1.0. CCMS ti consente di adattare i controlli di moderazione dei contenuti per allinearli ai tuoi requisiti aziendali specifici, mantenendo al contempo le protezioni essenziali e responsabili dell'IA. Per determinare se il tuo caso d'uso aziendale è idoneo per CCMS, contatta il tuo account manager Amazon Web Services.

Amazon Nova Forge fornisce un kit di strumenti per l'intelligenza artificiale responsabile che include dati di formazione, benchmark di valutazione e controlli di runtime per aiutarti ad allineare i tuoi modelli alle linee guida sull'intelligenza artificiale responsabile di Amazon Nova.

Dati di formazione: la categoria «RAI» nella miscelazione dei dati contiene casi e scenari che enfatizzano i principi dell'intelligenza artificiale responsabile, le considerazioni sulla sicurezza e l'implementazione responsabile della tecnologia. Utilizzali per allineare i tuoi modelli in modo responsabile durante la formazione preliminare continua.

Valutazioni: sono disponibili attività di benchmark per testare la capacità del modello di rilevare e rifiutare contenuti inappropriati, dannosi o errati. Utilizzate queste valutazioni per misurare la differenza tra le prestazioni del modello base e le prestazioni del modello personalizzato.

## Formazione per i modelli Amazon Nova

La formazione dei modelli Amazon Nova SageMaker HyperPod supporta diverse tecniche, tra cui Continued Pre-Training (CPT), Supervised Fine-Tuning (SFT) e Reinforcement Fine-Tuning (RFT).

Ogni tecnica soddisfa esigenze di personalizzazione diverse e può essere applicata a diverse versioni del modello Amazon Nova.

## Argomenti

- [Preaddestramento continuo \(CPT\)](#)
- [Fine-tuning supervisionato \(SFT\)](#)
- [Reinforcement Fine-Tuning \(RFT\) attivo SageMaker HyperPod](#)

## Preaddestramento continuo (CPT)

La formazione continua (CPT) è una tecnica di formazione che estende la fase di pre-formazione di un modello base esponendolo a testo aggiuntivo senza etichetta proveniente da domini o corpora specifici. A differenza della messa a punto supervisionata, che richiede coppie di input-output etichettate, il CPT si basa su documenti non elaborati per aiutare il modello ad acquisire una conoscenza più approfondita di nuovi domini, apprendere la terminologia e gli schemi di scrittura specifici del dominio e adattarsi a particolari tipi di contenuti o aree tematiche.

Questo approccio è particolarmente utile quando si dispone di grandi volumi (decine di miliardi di token) di dati di testo specifici del dominio, come documenti legali, letteratura medica, documentazione tecnica o contenuti aziendali proprietari, e si desidera che il modello sviluppi la fluidità nativa in quel dominio. In genere, dopo la fase CPT, il modello deve essere sottoposto a ulteriori fasi di ottimizzazione delle istruzioni per consentire al modello di utilizzare le nuove conoscenze acquisite e completare attività utili.

## Modelli supportati

Il CPT è disponibile per i seguenti modelli Amazon Nova:

- Nova 1.0 (Micro, Lite, Pro)
- Nova 2.0 (versione leggera)

## Quando usare Nova 1.0 rispetto a Nova 2.0

La famiglia di modelli Amazon Nova offre diversi punti operativi in termini di rapporto prezzo/prestazioni per ottimizzare precisione, velocità e costi.

Scegli Nova 2.0 quando hai bisogno di quanto segue:

- Funzionalità di ragionamento avanzate per attività analitiche complesse
- Prestazioni superiori nella codifica, nella matematica e nella risoluzione di problemi scientifici
- Supporto per una maggiore durata del contesto
- Migliori prestazioni multilingue

#### Note

Il modello più grande non è sempre migliore. Considerate il compromesso tra costi e prestazioni e i vostri requisiti aziendali specifici nella scelta tra i modelli Nova 1.0 e Nova 2.0.

## CPT su Nova 2.0

Amazon Nova Lite 2.0 è un modello di ragionamento basato su set di dati più grandi e diversificati rispetto a Nova Lite 1.0. Nonostante sia un modello più grande, Nova Lite 2.0 offre un'inferenza più rapida rispetto a Nova Lite 1.0, offrendo al contempo funzionalità di ragionamento avanzate, lunghezze di contesto più lunghe e prestazioni multilingue migliorate.

Il CPT su Nova 2.0 consente di estendere queste funzionalità avanzate con i dati specifici del dominio, consentendo al modello di sviluppare competenze approfondite in aree specializzate pur mantenendo le sue capacità analitiche e di ragionamento superiori.

## Esempio di ricetta CPT

Di seguito è riportato un esempio di ricetta per CPT. Puoi trovare questa ricetta e altre nell'archivio delle [ricette](#).

```
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
```

## Preparazione dei dati per CPT su 2.0

### Requisiti per il formato dei dati

I set di dati di addestramento e convalida devono essere file JSONL secondo il formato mostrato di seguito, in cui ogni riga contiene un oggetto JSON che rappresenta una conversazione con i campi e la struttura richiesti. Ecco un esempio:

```
{"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"}
```

Le voci di testo devono contenere contenuti fluidi in modo naturale e di alta qualità che rappresentino il dominio di destinazione.

Verifica che i dati possano essere convertiti nel [formato Arrow](#). Usa lo script python qui sotto per aiutarti. Assicurati che venga utilizzata la `datasets==2.18.0` versione minima:

```
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)
```

Dovrebbe stampare lo stesso numero di righe presenti nel file JSONL.

Quando usi il datamixing, esegui il primo lavoro con. `max_steps=2` Ciò contribuirà a creare ottimizzazioni nel cluster per l'accesso ai dati e a verificare la disponibilità di tutti i datamix.

## Come preparare i dati per il CPT

I dati di formazione sono il fattore determinante più importante per il successo della formazione preliminare continua. Sebbene i dati CPT siano spesso descritti come «non etichettati», la realtà è molto più sfumata. Il modo in cui i dati sono strutturati, formattati e presentati determina se il modello acquisirà le conoscenze e le competenze necessarie per il caso d'uso aziendale.

### Preparazione di set di dati aziendali strutturati per CPT

Questa è una sfida comune per le aziende e le organizzazioni che costruiscono modelli di base specializzati nel loro settore. La maggior parte delle aziende dispone di ricchi archivi di dati strutturati: cataloghi di prodotti, profili utente, registri delle transazioni, invio di moduli, chiamate API e metadati operativi. A prima vista, questo sembra molto diverso dal testo web non strutturato tipicamente utilizzato nella formazione preliminare standard.

Per imparare in modo efficace dai dati aziendali strutturati, rifletti attentamente sulle attività a valle e progetta la presentazione dei dati in modo da forzare il modello ad apprendere le giuste relazioni predittive.

Per sfruttare appieno il potenziale della formazione preliminare continua, prendi in considerazione:

- Quali attività deve svolgere il modello al momento dell'inferenza
- Quali informazioni sono presenti nei dati grezzi
- Come strutturare i dati in modo che il modello impari a estrarre e manipolare le informazioni correttamente

Il semplice inserimento di dati strutturati nella formazione non insegnerà al modello a ragionare al riguardo. Modella attivamente la presentazione dei dati per guidare ciò che il modello apprende.

Nelle sezioni seguenti, è riportata una rassegna della letteratura che dimostra l'importanza dell'aumento dei dati e fornisce esempi di strategie di aumento per dati aziendali strutturati che forniranno idee utili su come trattare e organizzare i set di dati aziendali per il CPT.

### Dati strutturati per il CPT in letteratura

Il CPT può inserire informazioni sul dominio nel modello, ma spesso non riesce a renderle recuperabili e manipolabili quando gli input o le attività cambiano. Esperimenti controllati dimostrano che, senza ricorrere a diversi miglioramenti durante il pre-allenamento, i modelli memorizzano i dati in modi fragili che restano difficili da estrarre anche dopo una successiva regolazione delle

istruzioni, e raccomandano di iniettare istruzioni come segnali nelle prime fasi dell'allenamento. Per i dati semistrutturati, la serializzazione randomizzata e altri miglioramenti riducono il sovradimensionamento dello schema, motivo per cui il CPT dovrebbe essere affiancato alle attività in stile istruzione anziché essere eseguito prima e IFT dopo. Un lavoro incentrato sulla finanza rileva inoltre che la combinazione congiunta di dati CPT e di istruzioni in batch migliora la generalizzazione e riduce l'oblio rispetto alla ricetta sequenziale. Il report tecnico di Qwen converge sullo stesso modello integrando dati di istruzioni di alta qualità nella formazione preliminare stessa, che favorisce l'apprendimento contestuale e preserva le istruzioni seguite acquisendo nuove conoscenze di dominio.

L'aumento dei dati per corpora semistrutturati è una leva fondamentale. Il CPT, compatibile con i grafici sintetici, espande piccoli set di domini in corpora collegati a entità che insegnano esplicitamente le relazioni e i composti con recupero al momento dell'inferenza. La combinazione congiunta di istruzioni CPT plus offre prestazioni superiori alle pipeline sequenziali nel settore finanziario e del bilanciamento con dati generali riduce il degrado delle competenze generali. Il CPT per domini su larga scala è inoltre in grado di mantenere ampie capacità e persino di consentire compromessi tramite la fusione dei modelli, ma ritiene comunque che l'ottimizzazione delle istruzioni sia un passo successivo essenziale, rafforzando l'importanza dell'introduzione di segnali di istruzione durante il CPT.

Iniettare la diversità attraverso la randomizzazione e il rimescolamento

Una strategia generale che aiuta a insegnare in modo efficace i modelli a partire dai set di dati strutturati e semistrutturati consiste nel mescolare l'ordine dei campi nei set di dati e persino eliminare casualmente alcune chiavi.

Mescola i campi costringe il modello a leggere il significato di ogni valore anziché dove appare e ad apprendere le relazioni tra tutti i campi. Ad esempio, nel caso di un videogioco pubblicato su Amazon Store, quando «Titolo», «Piattaforma», «Prezzo», «Condizione» ed «Edizione» arrivano in diverse permutazioni, il modello non può basarsi sul principio «il terzo slot è la piattaforma»; deve associare le etichette ai valori e apprendere le relazioni bilaterali tra gli attributi:  $\text{title} \rightleftharpoons \text{platform}$ ,  $\text{platform} \rightleftharpoons \text{price}$ ,  $\text{condition} \rightleftharpoons \text{price}$ . Quindi può, ad esempio, dedurre una probabile piattaforma dal nome di un gioco e da un prezzo osservato, o stimare una fascia di prezzo plausibile dati un titolo e una piattaforma.

L'eliminazione casuale delle chiavi durante la serializzazione si comporta come la perdita di funzionalità: impedisce il co-adattamento su qualsiasi campo e costringe il modello a recuperare le informazioni mancanti dalle prove rimanenti. Se «Piattaforma» è assente, il modello deve recuperarlo dalla stringa del titolo o dal testo di compatibilità; se «Prezzo» è nascosto, deve triangolarlo tra piattaforma, edizione e condizione. Questo crea simmetria ( $A \rightarrow B$  e  $B \rightarrow A$ ), robustezza per elenchi

disordinati del mondo reale e invarianza dello schema quando i campi sono mancanti, rinominati o riordinati.

Un esempio in stile shopping lo rende concreto. Serializza lo stesso articolo in diversi modi: «Titolo: 'Elden Ring' | Piattaforma: PlayStation 5 | Condizione: Usato—Come nuovo | Prezzo: \$34,99" e una permutazione come «Prezzo: \$34,99 | Titolo: 'Elden Ring' | Condizione: Usato—Come nuovo | Piattaforma: PlayStation 5", e in alcuni passaggi elimina «Piattaforma» lasciando «Compatibile con» nella descrizione. PS5 Addestra obiettivi complementari come la previsione della piattaforma da {title, price} e la previsione di un intervallo di prezzo da {title, platform}. Poiché l'ordine e persino la presenza delle chiavi variano, l'unica strategia stabile consiste nell'apprendere le vere relazioni tra gli attributi anziché memorizzare un modello.

Il modo in cui i dati vengono presentati è importante

LLMs impara prevedendo il token successivo in base a ciò che hanno già visto. Quindi l'ordine dei campi e degli eventi mostrati durante l'allenamento decide cosa può imparare il modello. Se il formato dell'allenamento corrisponde al compito reale, la perdita ricade sugli esatti token decisionali. Se i campi vengono messi insieme senza struttura, il modello impara le scorciatoie da tastiera o memorizza la popolarità e poi fallisce quando gli viene chiesto di scegliere tra le opzioni.

Mostra prima la situazione, poi le opzioni e poi la decisione. Se il modello deve anche conoscere i risultati o le spiegazioni, inseriscili dopo la decisione.

Esempi di imballaggio per CPT

Che cos'è l'imballaggio?

Significa semplicemente riempire ogni finestra di sequenza dei dati di addestramento con più esempi interi in modo che la finestra sia densa di token reali, non di riempimento.

Perché è importante

Durante l'allenamento viene impostata una lunghezza massima del contesto, ad esempio 8.192 token. I batch sono modellati in base a [dimensione del batch × lunghezza del contesto]. Se un esempio di allenamento è più corto della lunghezza del contesto, le posizioni rimanenti vengono riempite. Il padding continua a pesare sull'attenzione e sui kernel MLP anche se la perdita è mascherata, quindi l'elaborazione viene pagata per i token che non trasmettono alcun segnale di apprendimento.

Come fare l'imballaggio?

Per imballare più campioni, concatena più campioni di addestramento con un [DOC] separatore intermedio (nota lo spazio prima e dopo il [DOC]) in modo che l'intera lunghezza dei campioni sia inferiore alla lunghezza del contesto desiderata.

Un esempio di documento compresso sarebbe simile al seguente:

```
{"text": "training sample 1 [DOC] training sample 2 [DOC] training sample 3"}
```

## Parametri di ottimizzazione CPT

I parametri disponibili per la regolazione fine con CPT includono:

### Configurazione delle esecuzioni

- **nome:** Un nome descrittivo per il tuo lavoro di formazione. Questo aiuta a identificare il tuo lavoro nella console AWS di gestione.
- **model\_type:** la variante del modello Amazon Nova da utilizzare. Le opzioni disponibili sono. `amazon.nova-2-lite-v1:0:256k`
- **model\_name\_or\_path:** il percorso verso il modello base da utilizzare per l'allenamento. Le opzioni disponibili sono `nova-lite-2/prod` o il percorso S3 per il checkpoint post-allenamento (`()`). `s3://customer-escrow-bucket-unique_id/training_run_name`
- **repliche:** il numero di istanze di calcolo da utilizzare per l'addestramento distribuito. I valori disponibili variano in base al modello scelto. Amazon Nova Lite 2.0 supporta 4, 8, 16 o 32 repliche.
- **data\_s3\_path:** la posizione S3 del set di dati di addestramento, che è un file JSONL. Questo file deve risiedere nello stesso account e nella stessa regione del cluster. AWS Tutte le posizioni S3 fornite devono trovarsi nello stesso account e nella stessa Regione.
- **validation\_data\_s3\_path:** (Facoltativo) La posizione S3 del set di dati di convalida, che è un file JSONL. Questo file deve trovarsi nello stesso account e nella stessa Regione del cluster. Tutte le posizioni S3 fornite devono trovarsi nello stesso account e nella stessa Regione.
- **output\_s3\_path:** la posizione S3 in cui sono archiviati il manifest e i log. TensorBoard Tutte le sedi S3 fornite devono trovarsi nello stesso account e nella stessa regione. AWS AWS
- **mlflow\_tracking\_uri:** L'ARN dell'app da utilizzare per la registrazione MLFlow MLFlow
- **MLFlow mlflow\_experiment\_name:** nome dell'esperimento
- **mlflow\_run\_name:** nome MLFlow dell'esecuzione

### Configurazione dell'allenamento

- `max_length`: la lunghezza massima della sequenza in token. Determina la dimensione della finestra di contesto per l'addestramento. Il valore massimo supportato è di 8.192 token per CPT.

Sequenze più lunghe migliorano l'efficienza di addestramento a scapito di maggiori requisiti di memoria. Ti consigliamo di abbinare il parametro `max_length` alla distribuzione dei dati.

- `global_batch_size`: il numero totale di esempi di formazione elaborati insieme in un unico passaggio avanti o indietro su tutti i dispositivi e gli operatori.

Questo valore moltiplica la dimensione del batch per dispositivo e il numero di dispositivi.

Influisce sulla stabilità dell'addestramento e sul throughput. È consigliabile iniziare con un batch di dimensioni idonee per la memoria e quindi aumentare verticalmente. Per i dati specifici del dominio, batch di dimensioni maggiori potrebbero rendere i gradienti eccessivamente uniformi.

### Impostazioni del trainer

- `max_steps`: il numero di fasi di allenamento da eseguire. Ogni passaggio addestrerà il modello con il `global_batch_size` numero di elementi

### Impostazioni del modello

- `hidden_dropout`: La probabilità di eliminare gli output di stato nascosti. Aumenta questo valore di circa 0,0-0,2 per ridurre l'overfitting su set di dati più piccoli. I valori validi sono compresi tra 0 e 1, entrambi inclusi.
- `attention_dropout`: La probabilità di far cadere i pesi di attenzione. Questo parametro può agevolare la generalizzazione. I valori validi sono compresi tra 0 e 1, entrambi inclusi.

### Configurazione dell'ottimizzatore

- `lr`: Il tasso di apprendimento, che controlla la dimensione del passo durante l'ottimizzazione. Sono consigliabili valori compresi tra  $1e-6$  e  $1e-4$  per ottenere buone prestazioni. I valori validi sono compresi tra 0 e 1, entrambi inclusi.
- `nome`: L'algoritmo di ottimizzazione. Attualmente è supportato solo `distributed_fused_adam`.
- `weight_decay`: La forza di regolarizzazione L2. Valori maggiori (compresi tra 0,01 e 0,1) aumentano la regolarizzazione.

- `warmup_steps`: Il numero di passaggi per aumentare gradualmente il tasso di apprendimento. Migliora la stabilità dell'addestramento. I valori validi sono compresi tra 1 e 20, entrambi inclusi.
- `min_lr`: Il tasso minimo di apprendimento alla fine del decadimento. I valori validi sono compresi tra 0 e 1, entrambi inclusi, ma devono essere inferiori al tasso di apprendimento.

## Fine-tuning supervisionato (SFT)

Il processo di formazione SFT consiste in due fasi principali:

- Preparazione dei dati: segui le linee guida stabilite per creare, pulire o riformattare i set di dati nella struttura richiesta. Assicurati che gli input, gli output e le informazioni ausiliarie (come tracce di ragionamento o metadati) siano allineati e formattati correttamente.
- Configurazione dell'addestramento: definisci come verrà addestrato il modello. Quando viene utilizzata, questa configurazione è scritta in un file di ricette YAML che include:
  - Percorsi di origine dei dati (set di dati di formazione e convalida)
  - Iperparametri chiave (epoche, frequenza di apprendimento, dimensione del batch)
  - Componenti opzionali (parametri di allenamento distribuiti, ecc.)

## Confronto e selezione dei modelli Nova

Amazon Nova 2.0 è un modello addestrato su un set di dati più ampio e diversificato rispetto ad Amazon Nova 1.0. I miglioramenti includono:

- Capacità di ragionamento avanzate con supporto della modalità di ragionamento esplicito
- Prestazioni multilingue più ampie in altre lingue
- Prestazioni migliorate su attività complesse, tra cui la codifica e l'uso degli strumenti
- Gestione estesa del contesto con maggiore precisione e stabilità a lunghezze di contesto più lunghe

## Quando usare Nova 1.0 rispetto a Nova 2.0

Scegli Amazon Nova 2.0 quando:

- Sono necessarie prestazioni superiori con funzionalità di ragionamento avanzate
- È necessario un supporto multilingue o una gestione di attività complesse

- Sono necessari risultati migliori in termini di codifica, utilizzo di strumenti o attività analitiche

## SFT su Nova 2.0

Amazon Nova Lite 2.0 offre funzionalità avanzate per la regolazione fine supervisionata, tra cui la modalità di ragionamento avanzato, una migliore comprensione multimodale e una gestione estesa del contesto. SFT su Nova 2.0 ti consente di adattare queste potenti funzionalità ai tuoi casi d'uso specifici, mantenendo al contempo le prestazioni superiori del modello in attività complesse.

Le caratteristiche principali di SFT su Nova 2.0 includono:

- Supporto in modalità di ragionamento: addestra i modelli per generare tracce di ragionamento esplicite prima delle risposte finali per funzionalità analitiche avanzate.
- Formazione multimodale avanzata: perfeziona la comprensione dei documenti (PDF), la comprensione dei video e le attività basate su immagini con una maggiore precisione.
- Funzionalità di richiamo degli strumenti: addestrate i modelli a utilizzare efficacemente strumenti esterni e richiamare funzioni per flussi di lavoro complessi.
- Supporto contestuale esteso: sfrutta finestre contestuali più lunghe con maggiore stabilità e precisione per applicazioni che richiedono un uso intensivo di documenti.

### Note

Per ulteriori informazioni sulle immagini dei contenitori o sulle ricette di esempio da utilizzare, consulta le [ricette di Amazon Nova](#).

## Argomenti

- [Selezione della modalità di ragionamento \(solo Nova 2.0\)](#)
- [Strumento che chiama il formato dei dati](#)
- [Comprensione del documento, formato dei dati](#)
- [Video Understanding for SFT](#)
- [Istruzioni per il caricamento dei dati](#)
- [Creazione di un Fine-Tuning Job](#)
- [Parametri di ottimizzazione SFT](#)



- [Guida agli iperparametri](#)

## Esempio di ricetta SFT

Di seguito è riportato un esempio di ricetta per SFT. Puoi trovare questa ricetta e altre nell'archivio delle [ricette](#).

```
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:
 lr: 1e-5 # Optimizer settings
 # 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
```

## Selezione della modalità di ragionamento (solo Nova 2.0)

Amazon Nova 2.0 supporta la modalità di ragionamento per funzionalità analitiche avanzate:

- Modalità di ragionamento (abilitata):
  - Impostata `reasoning_enabled: true` nella configurazione di allenamento
  - Modella i treni per generare tracce di ragionamento prima delle risposte finali
  - Migliora le prestazioni in attività di ragionamento complesse
- Modalità non ragionata (disabilitata):
  - Imposta `reasoning_enabled: false` o ometti il parametro (impostazione predefinita)
  - SFT standard senza ragionamento esplicito
  - Adatto per attività che non traggono vantaggio dal ragionamento step-by-step

### Note

- Quando il ragionamento è abilitato, funziona con un elevato sforzo di ragionamento. Non esiste un'opzione di ragionamento basso per SFT.
- Il contenuto di ragionamento multimodale non è supportato per SFT. La modalità di ragionamento si applica agli input di solo testo.

## Utilizzo della modalità di ragionamento con set di dati non ragionanti

È consentito addestrare Amazon Nova su un set di dati non ragionevoli con `reasoning_enabled: true`. Tuttavia, così facendo il modello potrebbe perdere le sue capacità di ragionamento, poiché Amazon Nova impara principalmente a generare le risposte presentate nei dati senza applicare il ragionamento.

Se si esegue l'addestramento di Amazon Nova su un set di dati non ragionante ma si desidera comunque utilizzare il ragionamento durante l'inferenza:

1. Disattiva il ragionamento durante l'allenamento () `reasoning_enabled: false`
2. Abilita il ragionamento in un secondo momento durante l'inferenza

Sebbene questo approccio consenta il ragionamento in fase di inferenza, non garantisce prestazioni migliori rispetto all'inferenza senza ragionamento.

Procedura ottimale: abilita il ragionamento sia per l'addestramento che per l'inferenza quando si utilizzano set di dati di ragionamento e disabilitalo per entrambi quando si utilizzano set di dati non di ragionamento.

#### Note

Per ulteriori informazioni sulle immagini dei contenitori o sulle ricette di esempio da utilizzare, consulta le [ricette di Amazon Nova](#).

Strumento che chiama il formato dei dati

SFT supporta modelli di addestramento all'uso degli strumenti (chiamata di funzioni). Di seguito è riportato un esempio di formato di input per la chiamata degli strumenti:

Esempio di input:

```
{
 "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?"
 }
]
 }
]
}

```

Considerazioni importanti per i dati di chiamata degli strumenti:

- ToolUse deve comparire solo nei turni degli assistenti
- ToolResult deve apparire solo nei turni degli utenti
- ToolResult deve essere solo testo o JSON; altre modalità non sono attualmente supportate per i modelli Amazon Nova
- L'InputSchema all'interno di ToolSpec deve essere un oggetto JSON Schema valido
- Ciascuno ToolResult deve fare riferimento a un assistente valido toolUseId di un precedente ToolUse, e ognuno deve essere usato esattamente una volta per conversazione toolUseId

#### Note

Per ulteriori informazioni sulle immagini dei contenitori o sulle ricette di esempio da utilizzare, consulta le [ricette di Amazon Nova](#).

## Comprensione del documento, formato dei dati

SFT supporta modelli di formazione sulle attività di comprensione dei documenti. Di seguito è riportato un esempio di formato di input:

### Esempio di input

```
{
 "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"
 }
]
 }
]
```

Considerazioni importanti per la comprensione dei documenti:

- Sono supportati solo i file PDF
- La dimensione massima del documento è di 10 MB
- Un esempio può contenere documenti e testo, ma non può combinare documenti con altre modalità (come immagini o video)

#### Note

Per ulteriori informazioni sulle immagini dei contenitori o sulle ricette di esempio da utilizzare, consulta le [ricette di Amazon Nova](#).

## Video Understanding for SFT

SFT supporta modelli di ottimizzazione per le attività di comprensione video. Di seguito è riportato un esempio di formato di input:

### Esempio di input

```
{
 "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"
 }
]
 }
]
}

```

Considerazioni importanti per la comprensione dei video:

- I video possono avere una dimensione massima di 50 MB
- I video possono avere una durata massima di 15 minuti
- È consentito un solo video per campione; non sono supportati più video nello stesso campione
- Un campione può contenere video e testo, ma non può combinare video con altre modalità (come immagini o documenti)

 Note

Per ulteriori informazioni sulle immagini dei contenitori o sulle ricette di esempio da utilizzare, consulta le [ricette di Amazon Nova](#).

## Istruzioni per il caricamento dei dati

Carica i set di dati di formazione e convalida in un bucket S3. Specificate queste posizioni nel blocco della ricetta: `run`

```
Run config
run:
 ...
 data_s3_path: "s3://<bucket-name>/<training-directory>/<training-file>.jsonl"
```

Nota: sostituisci `<bucket-name><training-directory>`, `<validation-directory><training-file>`, e `<validation-file>` con percorsi S3 effettivi.

Nota: i set di dati di convalida non sono attualmente supportati per SFT con Amazon Nova 2.0. Se viene fornito un set di dati di convalida, questo verrà ignorato.

## Creazione di un Fine-Tuning Job

Definisci il modello base utilizzando i `model_name_or_path` campi `model_type` e nel blocco: `run`

```
Run config
run:
 ...
 model_type: amazon.nova-2-lite-v1:0:256k
 model_name_or_path: nova-lite-2/prod
 ...
```

## Parametri di ottimizzazione SFT

I parametri disponibili per la regolazione con SFT includono:

### Configurazione delle esecuzioni

- **name:** Un nome descrittivo per il tuo lavoro di formazione. Questo aiuta a identificare il tuo lavoro nella console AWS di gestione.
- **model\_type:** la variante del modello Amazon Nova da utilizzare. Le opzioni disponibili sono. `amazon.nova-2-lite-v1:0:256k`
- **model\_name\_or\_path:** il percorso verso il modello base da utilizzare per l'allenamento. Le opzioni disponibili sono `nova-lite-2/prod` o il percorso S3 per il checkpoint post-allenamento (`()`). `s3://customer-escrow-bucket-unique_id/training_run_name`
- **repliche:** il numero di istanze di calcolo da utilizzare per l'addestramento distribuito. I valori disponibili variano in base al modello scelto. Amazon Nova Lite 2.0 supporta 4, 8, 16 o 32 repliche.
- **data\_s3\_path:** la posizione S3 del set di dati di addestramento, che è un file JSONL. Questo file deve risiedere nello stesso account e nella stessa regione del cluster. AWS Tutte le posizioni S3 fornite devono trovarsi nello stesso account e nella stessa Regione.
- **validation\_data\_s3\_path:** (Facoltativo) La posizione S3 del set di dati di convalida, che è un file JSONL. Questo file deve trovarsi nello stesso account e nella stessa Regione del cluster. Tutte le posizioni S3 fornite devono trovarsi nello stesso account e nella stessa Regione.
- **output\_s3\_path:** la posizione S3 in cui sono archiviati il manifest e i log. TensorBoard Tutte le sedi S3 fornite devono trovarsi nello stesso account e nella stessa regione. AWS AWS
- **mlflow\_tracking\_uri:** L'ARN dell'app da utilizzare per la registrazione. MLFlow MLFlow
- **MLFlow mlflow\_experiment\_name:** nome dell'esperimento.
- **mlflow\_run\_name:** nome dell'esecuzione. MLFlow

## Configurazione dell'allenamento

- **max\_steps:** il numero di fasi di allenamento da eseguire. Ogni fase addestrerà il modello con il `global_batch_size` numero di elementi.
- **save\_steps:** La frequenza (in fasi) con cui salvare i checkpoint del modello durante l'allenamento.
- **save\_top\_k:** il numero massimo di migliori checkpoint da conservare in base alle metriche di convalida.
- **max\_length:** la lunghezza massima della sequenza in token. Determina la dimensione della finestra di contesto per l'addestramento. Il valore massimo supportato è 32768 token per SFT.

Sequenze più lunghe migliorano l'efficienza di addestramento a scapito di maggiori requisiti di memoria. Ti consigliamo di abbinare il parametro `max_length` alla distribuzione dei dati.

- `global_batch_size`: il numero totale di esempi di formazione elaborati insieme in un unico passaggio avanti o indietro su tutti i dispositivi e gli operatori.

Questo valore moltiplica la dimensione del batch per dispositivo e il numero di dispositivi.

Influisce sulla stabilità dell'addestramento e sul throughput. È consigliabile iniziare con un batch di dimensioni idonee per la memoria e quindi aumentare verticalmente. Per i dati specifici del dominio, batch di dimensioni maggiori potrebbero rendere i gradienti eccessivamente uniformi.

- `reasoning_enabled`: flag booleano per abilitare le funzionalità di ragionamento durante l'allenamento.

## Learning Rate Scheduler

- `warmup_steps`: Il numero di passaggi per aumentare gradualmente il tasso di apprendimento. Migliora la stabilità dell'addestramento.
- `min_lr`: Il tasso minimo di apprendimento alla fine del decadimento. I valori validi sono compresi tra 0 e 1, entrambi inclusi, ma devono essere inferiori al tasso di apprendimento.

## Configurazione dell'ottimizzatore

- `lr`: Il tasso di apprendimento, che controlla la dimensione del passo durante l'ottimizzazione. Sono consigliabili valori compresi tra  $1e-6$  e  $1e-4$  per ottenere buone prestazioni. I valori validi sono compresi tra 0 e 1, entrambi inclusi.
- `weight_decay`: La forza di regolarizzazione L2. Valori maggiori (compresi tra 0,01 e 0,1) aumentano la regolarizzazione.
- `adam_beta1`: Il tasso di decadimento esponenziale per le stime del primo momento in Adam Optimizer. L'impostazione predefinita è 0,9.
- `adam_beta2`: il tasso di decadimento esponenziale per le stime del secondo momento in Adam Optimizer. Il valore predefinito è 0,95.

## Configurazione PEFT

- `peft_scheme`: lo schema di regolazione fine efficiente in termini di parametri da utilizzare. Le opzioni sono `'null'` per la messa a punto completa o per la regolazione di precisione basata su LoRa. `lora`

## LoRa Tuning (quando peft\_scheme è 'lora')

- **alpha**: Il parametro di scala LoRa. Controlla l'entità dell'adattamento di basso rango. I valori tipici vanno da 8 a 128.
- **lora\_plus\_lr\_ratio**: Il rapporto del tasso di apprendimento per l'ottimizzazione di LoRA+. Questo moltiplicatore regola il tasso di apprendimento in modo specifico per i parametri LoRa.

## Guida agli iperparametri

Utilizza i seguenti iperparametri consigliati in base all'approccio di allenamento:

### Allenamento di livello completo

- **Epoche**: 1
- **Tasso di apprendimento (lr)**: 1e-5
- **Tasso minimo di apprendimento (min\_lr)**: 1e-6

### LoRa (adattamento a basso rango)

- **Epoche**: 2
- **Tasso di apprendimento (lr)**: 5e-5
- **Tasso minimo di apprendimento (min\_lr)**: 1e-6

Nota: modifica questi valori in base alle dimensioni del set di dati e alle prestazioni di convalida. Monitora le metriche di allenamento per evitare un sovradimensionamento.

## Reinforcement Fine-Tuning (RFT) attivo SageMaker HyperPod

Reinforcement Fine-Tuning (RFT) è una tecnica di apprendimento automatico che migliora le prestazioni del modello attraverso segnali di feedback (punteggi misurabili o premi che indicano la qualità della risposta) anziché la supervisione diretta con risposte esatte e corrette. A differenza della tradizionale regolazione di precisione supervisionata che apprende dalle coppie input-output, RFT utilizza le funzioni di ricompensa per valutare le risposte del modello e ottimizza iterativamente il modello per massimizzare tali ricompense.

Questo approccio è particolarmente efficace per le attività in cui è difficile definire l'output esatto e corretto, ma è possibile misurare in modo affidabile la qualità della risposta. RFT consente ai modelli

di apprendere comportamenti e preferenze complessi attraverso prove e feedback, il che lo rende ideale per applicazioni che richiedono un processo decisionale articolato, una risoluzione creativa dei problemi o il rispetto di criteri di qualità specifici che possono essere valutati programmaticamente.

## Quando usare RFT

Usa RFT quando puoi definire criteri di successo chiari e misurabili ma hai difficoltà a fornire risultati esatti e corretti per la formazione. È ideale per attività in cui la qualità è soggettiva o multiforme, come la scrittura creativa, l'ottimizzazione del codice o il ragionamento complesso, in cui esistono più soluzioni valide ma alcune sono chiaramente migliori di altre.

RFT funziona al meglio quando si dispone di quanto segue:

- Una funzione di ricompensa affidabile in grado di valutare gli output del modello in modo programmatico
- È necessario allineare il comportamento del modello a preferenze o vincoli specifici
- Situazioni in cui la messa a punto tradizionale con supervisione non è sufficiente perché la raccolta di esempi etichettati di alta qualità è costosa o poco pratica

Prendi in considerazione RFT per le applicazioni che richiedono miglioramenti iterativi, personalizzazione o aderenza a regole aziendali complesse che possono essere codificate come segnali di ricompensa.

## Per cosa RFT è più adatto

RFT eccelle nei settori in cui la qualità dell'output può essere misurata oggettivamente, ma le risposte ottimali sono difficili da definire in anticipo:

- Risoluzione matematica dei problemi: correttezza verificabile con percorsi di soluzione multipli
- Generazione e ottimizzazione del codice: risultati di esecuzione testabili e metriche prestazionali
- Compiti di ragionamento scientifico: coerenza logica e accuratezza dei fatti
- Analisi strutturata dei dati: output verificabili a livello di codice
- Ragionamento in più fasi: attività che richiedono una progressione logica step-by-step
- Utilizzo degli strumenti e chiamate API: successo misurabile in base ai risultati di esecuzione
- Flussi di lavoro complessi: rispetto di vincoli e regole aziendali specifici

RFT funziona eccezionalmente bene quando è necessario bilanciare più obiettivi concorrenti come precisione, efficienza e stile.

Quando utilizzare la modalità di ragionamento per l'allenamento RFT

Amazon Nova 2.0 supporta la modalità di ragionamento durante l'addestramento RFT. Sono disponibili le seguenti modalità:

- nessuno: nessun ragionamento (ometti il campo `reasoning_effort`)
- basso: sovraccarico minimo di ragionamento
- high: massima capacità di ragionamento (impostazione predefinita quando è specificato `reasoning_effort`)

 Note

Non esiste un'opzione media per RFT. Se il campo `reasoning_effort` non è presente nella configurazione, il ragionamento è disabilitato.

Usa un ragionamento elevato per quanto segue:

- Compiti analitici complessi
- Risoluzione di problemi matematici
- Deduzione logica in più fasi
- Attività in cui il step-by-step pensiero aggiunge valore

Usa none (ometti `reasoning_effort`) o low reasoning per quanto segue:

- Semplici domande fattuali
- Classificazioni dirette
- Ottimizzazione della velocità e dei costi
- Risposta semplice alle domande

### Important

Le modalità di ragionamento più avanzate aumentano i tempi e i costi di formazione, la latenza e i costi dell'inferenza, ma aumentano anche la capacità del modello per attività di ragionamento complesse.

## Modelli supportati

RFT onSageMaker HyperPod supporta Amazon Nova Lite 2.0 (amazon.nova-2-lite-v 1:0:256k).

## Fasi principali

Il processo RFT prevede quattro fasi chiave:

- Implementazione di un valutatore: crea una funzione di ricompensa per assegnare un punteggio programmatico alle risposte del modello in base ai tuoi criteri di qualità.
- Istruzioni di caricamento: prepara e carica i dati di allenamento nel formato conversazionale specificato con dati di riferimento per la valutazione.
- Avvio di un lavoro: avvia il processo di messa a punto del rinforzo con i parametri configurati.
- Monitoraggio: monitora i progressi della formazione tramite dashboard di metriche per garantire che il modello apprenda in modo efficace.

Ogni fase si basa su quella precedente e il valutatore funge da base che guida l'intero processo di formazione fornendo segnali di feedback coerenti.

## Argomenti

- [RFT su Nova 2.0](#)

## RFT su Nova 2.0

I dati di addestramento RFT seguono il formato conversazionale OpenAI. Ogni esempio di addestramento è un oggetto JSON contenente messaggi, risposte di riferimento e definizioni di strumenti opzionali. Questa sezione fornisce indicazioni sulla preparazione di dati di addestramento efficaci per RFT su Nova 2.0.

## Argomenti

- [Formato e struttura dei dati](#)



- [Descrizioni dei campi](#)
- [Guida agli iperparametri](#)
- [Proprietà aggiuntive](#)
- [Suggerimenti sulle dimensioni dei set di dati](#)
- [Caratteristiche dei dati di allenamento efficaci](#)
- [Monitoraggio della formazione RFT](#)

## Formato e struttura dei dati

Ogni esempio di addestramento è un oggetto JSON contenente quanto segue:

- **messaggi**: una serie di turni di conversazione che utilizzano ruoli di sistema, utente e, facoltativamente, assistente
- **reference\_answer**: risultato previsto o criteri di valutazione per il calcolo della ricompensa
- **strumenti (opzionale)**: serie di definizioni di funzioni disponibili per il modello
- **id (opzionale)**: identificatore univoco per il tracciamento e la deduplicazione

Ogni esempio deve essere su una sola riga del file JSONL, con un oggetto JSON per riga.

### Esempio 1: problema di chimica

L'esempio seguente mostra un problema di chimica con una risposta di riferimento contenente valori di verità fondamentali:

```
{
 "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 0 atoms with lone pairs (4 acceptors)"
 }
}

```

### Note

Il `reference_answer` contiene valori di verità fondamentali calcolati utilizzando regole specifiche del dominio. La tua funzione di ricompensa confronta i valori previsti del modello con questi valori di riferimento per calcolare un punteggio di ricompensa.

## Esempio 2: problema matematico

L'esempio seguente mostra un problema di matematica con passaggi di soluzione:

```

{
 "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": [" $2x = 13 - 5$ ", " $2x = 8$ ", " $x = 4$ "]
 }
}

```

## Esempio 3: utilizzo degli strumenti

L'esempio seguente mostra l'utilizzo dello strumento con il comportamento previsto:

```

{
 "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"
}
}
```

## Descrizioni dei campi

| Campo                   | Description                                                                 | Note aggiuntive                                                                                                               | Richiesto |
|-------------------------|-----------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------|-----------|
| id                      | Identificatore univoco per questo esempio RFT                               | Stringa (ad esempio, «sample-001»). Utile per il tracciamento e la deduplicazione.                                            | No        |
| messages                | Elenco ordinato di messaggi di chat che definiscono il prompt e il contesto | Array di oggetti . Il modello li vede in ordine. In genere inizia con un messaggio di sistema, quindi l'utente.               | Sì        |
| messages [].role        | Chi sta parlando nel messaggio                                              | Valori comuni: «sistema», «utente» (a volte «assistente» in altri contesti)                                                   | No        |
| messaggi [].content     | Il contenuto testuale del messaggio                                         | Stringa semplice. Per il sistema sono le istruzioni, per l'utente è l'attività o l'input.                                     | No        |
| strumenti               | Specifiche dell'utente disponibili per il modello durante questo esempio    | Array. Ogni elemento definisce l'interfaccia e i metadati di uno strumento . I tipi possono includere «funzione» o «interno». | No        |
| risposta_di riferimento | L'output del modello previsto per questo esempio                            | Stringa o oggetto a seconda dell'attività. Utilizzato come                                                                    | No        |

| Campo | Description | Note aggiuntive                               | Richiesto |
|-------|-------------|-----------------------------------------------|-----------|
|       |             | obiettivo per la valutazione o la formazione. |           |

#### Note

Eventuali campi personalizzati aggiuntivi (ad esempio, `task_id`, `difficy_level`, `context_data`) non vengono convalidati e verranno passati alla funzione di ricompensa come metadati.

## Guida agli iperparametri

Utilizza i seguenti iperparametri consigliati in base al tuo approccio di allenamento:

### Generale:

- Epoche: 1
- Tasso di apprendimento (lr):  $1e-7$
- Numero di generazioni: 8
- Numero massimo di nuovi token: 8192
- Dimensione del lotto: 256

### LoRa (adattamento a basso rango):

- Grado LoRa: 32

#### Note

Modifica questi valori in base alle dimensioni del set di dati e alle prestazioni di convalida. Monitora le metriche di allenamento per evitare un sovradimensionamento.

## Proprietà aggiuntive

L'impostazione «AdditionalProperties»: true consente di includere campi personalizzati oltre ai requisiti di base dello schema, offrendo la flessibilità necessaria per aggiungere tutti i dati necessari alla funzione di ricompensa per una corretta valutazione.

### Campi aggiuntivi comuni

È possibile includere i seguenti tipi di campi aggiuntivi:

#### Metadati:

- `task_id`: identificatore univoco per il tracciamento
- `difficulty_level`: indicatore di complessità del problema
- `dominio`: area tematica o categoria
- `expected_reasoning_steps`: numero di passaggi nella soluzione

#### Criteri di valutazione:

- `evaluation_criteria`: Rubriche di valutazione specifiche
- `custom_scoring_weights`: importanza relativa dei diversi aspetti
- `context_data`: informazioni di base sul problema
- `external_references`: collegamenti alla documentazione o alle risorse pertinenti

### Esempio con proprietà aggiuntive

L'esempio seguente include campi di metadati personalizzati:

```
{
 "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
}
```

## Suggerimenti sulle dimensioni dei set di dati

### Punto di partenza

Inizia con le seguenti dimensioni minime dei set di dati:

- Almeno 100 esempi di formazione
- Minimo 100 esempi di valutazione

Dai priorità ai dati di input di alta qualità e a una funzione di ricompensa affidabile che viene eseguita in modo coerente sulle risposte del modello.

### Approccio incentrato sulla valutazione

Prima di investire nella formazione RFT su larga scala, valuta le prestazioni di base del tuo modello:

- Prestazioni elevate (ricompensa superiore al 95%): la tecnologia RFT potrebbe non essere necessaria, in quanto il modello offre già buone prestazioni
- Prestazioni molto scarse (ricompensa dello 0%): passate innanzitutto a SFT per stabilire le funzionalità di base
- Prestazioni moderate: la tecnologia RFT è probabilmente appropriata

Questo approccio basato sulla valutazione assicura che la funzione di ricompensa sia priva di bug e determina se RFT è il metodo giusto per il tuo caso d'uso. Iniziare in piccolo consente di acquisire dimestichezza con il flusso di lavoro RFT, identificare e risolvere tempestivamente i problemi, convalidare l'approccio prima dell'ampliamento e testare l'affidabilità delle funzioni di ricompensa. Una volta convalidato, puoi espanderlo a set di dati più grandi per migliorare ulteriormente le prestazioni.

## Caratteristiche dei dati di allenamento efficaci

### Chiarezza e coerenza

I buoni esempi RFT richiedono dati di input chiari e inequivocabili che consentano un calcolo accurato della ricompensa tra i diversi output del modello. Evita il rumore nei tuoi dati, tra cui:

- Formattazione non coerente
- Etichette o istruzioni contraddittorie
- Istruzioni ambigue
- Risposte di riferimento contrastanti

Qualsiasi ambiguità indurrà in errore il processo di formazione e indurrà il modello ad apprendere comportamenti non intenzionali.

### Diversità

Il tuo set di dati dovrebbe catturare l'intera diversità dei casi d'uso di produzione per garantire solide prestazioni nel mondo reale. Include:

- Vari tipi di problemi e livelli di difficoltà
- Diversi formati di input e casi limite
- Esempi rappresentativi di tutti gli scenari previsti

Questa diversità aiuta a prevenire l'overfit e garantisce che il modello gestisca gli input non familiari con garbo.

### Considerazioni sulla funzione di ricompensa

Progetta la tua funzione di ricompensa per un allenamento efficiente:

- Esegui in pochi secondi (non in minuti)
- Parallelizza efficacemente con Lambda
- Restituisci punteggi coerenti e affidabili
- Gestisci con eleganza diversi tipi di output del modello

Le funzioni di ricompensa veloci e scalabili consentono un'iterazione rapida e una sperimentazione economica su larga scala.



## Monitoraggio della formazione RFT

Monitora le metriche chiave durante la formazione per garantire un apprendimento efficace e identificare tempestivamente potenziali problemi.

### Argomenti

- [Metriche chiave da monitorare](#)
- [Valutazione dopo RFT](#)
- [Utilizzo di modelli ottimizzati](#)
- [Limitazioni e procedure consigliate](#)
- [Risoluzione dei problemi](#)

### Metriche chiave da monitorare

Monitora le seguenti metriche utilizzate MIFlow durante l'allenamento:

#### Metriche sui premi:

- Punteggio medio di ricompensa: qualità complessiva delle risposte del modello (dovrebbe aumentare nel tempo)
- Distribuzione dei premi: percentuale di risposte che ricevono premi alti, medi e bassi
- Premi per la formazione e la convalida: confronta per individuare l'overfit

#### Metriche di formazione:

- Aggiornamenti delle norme: numero di aggiornamenti del peso eseguiti con successo
- Percentuale di completamento dell'implementazione: percentuale di campioni valutati con successo

#### Per quanto riguarda i modelli:

- Stabilizzazione dei premi (indica uno scarso apprendimento)
- I premi di convalida diminuiscono mentre aumentano i premi di formazione (sovradimensionamento)
- La varianza delle ricompense aumenta in modo significativo nel tempo (instabilità)
- Alta percentuale di errori nella funzione di ricompensa (problemi di implementazione)

Quando interrompere l'allenamento:

- Le metriche prestazionali prefissate sono state raggiunte
- I premi si stabilizzano e non migliorano più
- Le prestazioni di convalida peggiorano (è stato rilevato un sovradimensionamento)
- È stato raggiunto il budget massimo per la formazione

Valutazione dopo RFT

Al termine della formazione, valuta il tuo modello perfezionato per valutare i miglioramenti delle prestazioni:

- Esegui il processo di valutazione RFT: utilizza il checkpoint del tuo corso di formazione RFT come modello
- Confronto con quello di base: valuta sia il modello base che il modello perfezionato sullo stesso set di test
- Analizza le metriche: esamina le metriche specifiche delle attività (precisione, punteggi di ricompensa, ecc.)
- Esegui una revisione qualitativa: ispeziona manualmente i campioni in uscita per verificarne la qualità

Per le procedure di valutazione dettagliate, consultate la sezione Valutazione.

Utilizzo di modelli ottimizzati

Accesso ai posti di blocco:

Al termine dell'addestramento, individua il checkpoint:

1. Accedi al tuo `output_path` account in S3
2. Scarica ed estrai `output.tar.gz`
3. Aprire `manifest.json`
4. Copia il `checkpoint_s3_bucket` valore

Distribuzione per l'inferenza:

Usa il percorso S3 del checkpoint per l'inferenza o l'ulteriore formazione:

```
run:
 model_type: amazon.nova-2-lite-v1:0:256k
 model_name_or_path: "s3://customer-escrow-<account-number>-smtj-<unique-
 identifier>/<job-name>"
```

Per le istruzioni di distribuzione e inferenza, consulta la sezione Inferenza.

## Limitazioni e procedure consigliate

### Limitazioni attuali:

#### Restrizioni relative alla beta:

- È necessario creare un nuovo gruppo RIG per RFT. Questa limitazione verrà risolta da GA.
- Requisiti relativi al tipo di istanza: sono supportate solo le istanze P5 (minimo 8x P5.48xLarge). Prossimamente: supporto per tipi di istanze più piccoli (ETA: metà gennaio 2025).

### Limitazioni funzionali:

- Timeout Lambda di 15 minuti: le funzioni Reward devono essere completate entro 15 minuti
- Solo turno singolo: le conversazioni a turni multipli non sono supportate
- Set di dati di convalida: non supportati durante l'allenamento. Utilizza processi di valutazione separati per valutare i progressi della formazione.

### Considerazioni sulla formazione:

- Scenari con ricompense ridotte: potrebbero avere difficoltà quando meno del 5% degli esempi riceve ricompense positive: prendete in considerazione innanzitutto l'SFT
- Requisiti in materia di dati: è necessaria una diversità sufficiente per apprendere in modo efficace
- Costo computazionale: più costoso della regolazione fine supervisionata

### Nova Forge rimuove alcune di queste limitazioni:

- Supporta conversazioni a più turni
- Consente funzioni di ricompensa che superano i timeout di 15 minuti
- Fornisce algoritmi e opzioni di ottimizzazione avanzati

- Progettato per casi d'uso aziendali complessi, ottimizzato specificamente per creare modelli di frontiera

Le migliori pratiche:

Inizia in piccolo e scala:

- Inizia con set di dati minimi (100-200 esempi) e poche epoche di formazione
- Convalida il tuo approccio prima di ampliare
- Aumenta gradualmente le dimensioni del set di dati e le fasi di formazione in base ai risultati

Baseline con SFT innanzitutto:

- Se i punteggi di ricompensa sono costantemente bassi (ad esempio, sempre 0), esegui SFT prima di RFT
- RFT richiede prestazioni di base ragionevoli per migliorare efficacemente

Progetta funzioni di ricompensa efficienti:

- Esegui in pochi secondi, non in minuti
- Riduci al minimo le chiamate API esterne
- Utilizza algoritmi e strutture dati efficienti
- Implementa una corretta gestione degli errori
- Esegui un test accurato prima dell'allenamento
- Sfrutta le funzionalità di scalabilità parallela di Lambda

Monitora attivamente la formazione:

- Tieni traccia dei punteggi medi di ricompensa nel tempo
- Guarda la distribuzione delle ricompense tra i campioni
- Confronta i premi di formazione e quelli di convalida
- Cerca modelli preoccupanti (plateaus, overfitting, instabilità)

Iterate in base ai risultati:

- Se i premi non migliorano dopo diverse iterazioni, modifica il design della funzione di ricompensa
- Aumenta la diversità dei set di dati per fornire segnali di apprendimento più chiari
- Prendi in considerazione la possibilità di passare a SFT se i premi rimangono vicini allo zero
- Sperimenta con diversi iperparametri (tasso di apprendimento, dimensione del batch)

Ottimizza la qualità dei dati:

- Garantisci esempi diversi e rappresentativi
- Includi casi limite e campioni difficili
- La funzione Verify Reward assegna un punteggio corretto a tutti i tipi di esempi
- Rimuovi o correggi i campioni che confondono la funzione di ricompensa

Risoluzione dei problemi

Errori della funzione di ricompensa:

Sintomi: elevato tasso di errore nelle chiamate alla funzione di ricompensa durante l'allenamento

| Problema                           | Caratteristiche                                     | Risoluzione                                                                                                |
|------------------------------------|-----------------------------------------------------|------------------------------------------------------------------------------------------------------------|
| Timeout Lambda                     | Timeout frequenti dopo 15 minuti                    | Ottimizzate le prestazioni delle funzioni; prendete in considerazione Nova Forge per valutazioni complesse |
| Concorrenza insufficiente          | Errori di limitazione Lambda                        | Aumenta <code>lambda_concurrency_limit</code> o richiedi un aumento della quota                            |
| Formato di restituzione non valido | La formazione fallisce a causa di errori di formato | Verifica che la struttura restituita corrisponda al formato di interfaccia richiesto                       |
| Eccezioni non gestite              | Errori intermittenti                                | Aggiungi una gestione e una registrazione complete degli errori                                            |

| Problema                 | Caratteristiche      | Risoluzione                                                   |
|--------------------------|----------------------|---------------------------------------------------------------|
| Guasti delle API esterne | Punteggio incoerente | Implementa la logica dei tentativi e le strategie di fallback |

Scarse prestazioni di allenamento:

Sintomi: le ricompense non migliorano o si stabilizzano a valori bassi

Risoluzioni:

- Verifica della correttezza della funzione di ricompensa: prova con esempi noti good/bad
- Verifica le prestazioni di base: valuta il modello base; se la precisione è prossima allo zero, esegui prima l'SFT
- Aumenta la diversità dei dati: aggiungi esempi più vari che coprono diversi scenari
- Modifica gli iperparametri: prova diversi tassi di apprendimento o dimensioni di batch diverse
- Verifica la qualità del segnale di ricompensa: assicurati che i premi distinguano tra risposte positive e negative

Sovradattamento:

Sintomi: i premi di allenamento aumentano mentre i premi di convalida diminuiscono

Risoluzioni:

- Riduci le fasi di allenamento: interrompi l'allenamento prima
- Aumenta le dimensioni del set di dati: aggiungi altri esempi di formazione
- Aggiungi regolarizzazione: Regola o `weight_decay` `entropy_coeff`
- Aumenta la diversità dei dati: assicurati che il set di formazione rappresenti la distribuzione completa

## Valutazione di un modello addestrato

Una ricetta di valutazione è un file di configurazione YAML che definisce la modalità di esecuzione di un processo di valutazione dei modelli Amazon Nova. Con questa ricetta è possibile valutare

le prestazioni di un modello di base o addestrato rispetto a benchmark comuni o a set di dati personalizzati. Le metriche possono essere archiviate in Amazon TensorBoard S3 o. La valutazione fornisce metriche quantitative che permettono di valutare le prestazioni di un modello in varie attività per determinare se sono necessarie ulteriori personalizzazioni.

La valutazione dei modelli è un processo offline, in cui i modelli vengono testati rispetto a benchmark fissi con risposte predefinite. Non vengono valutati in tempo reale o in base alle interazioni attive degli utenti. Per le valutazioni in tempo reale, puoi valutare il modello dopo averlo distribuito su Amazon Bedrock richiamando il runtime di Amazon Bedrock. APIs

## Argomenti

- [Attività di benchmarking disponibili](#)
- [Informazioni sui parametri delle ricette](#)
- [Esempi di ricette di valutazione](#)
- [Avvio di un processo di valutazione](#)
- [Accesso e analisi dei risultati di valutazione](#)
- [Valutazione RFT](#)

## Attività di benchmarking disponibili

È disponibile un pacchetto di codice di esempio che dimostra come calcolare le metriche di benchmark utilizzando la funzionalità di valutazione del modello SageMaker AI per Amazon Nova.

[Per accedere ai pacchetti di codice, consulta sample-N. ova-lighteval-custom-task](#)

Di seguito è riportato un elenco dei benchmark standard di settore supportati e disponibili. È possibile specificare i benchmark seguenti nel parametro `eval_task`:

| Benchmark | Modalità | Description                                                      | Metriche    | Strategia | Sottoattività disponibile |
|-----------|----------|------------------------------------------------------------------|-------------|-----------|---------------------------|
| mmlu      | Testo    | Massive Multitask Language Understanding (MMLU)<br>- Verifica la | accuratezza | zs_cot    | Sì                        |

| Benchmark | Modalità | Description                                                                                                                                                                                                       | Metriche    | Strategia | Sottoattività disponibile |
|-----------|----------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------|-----------|---------------------------|
|           |          | conoscenza di 57 materie.                                                                                                                                                                                         |             |           |                           |
| mmlu_pro  | Testo    | MMLU -<br>Sottoinsieme professionale<br>- Incentrat<br>o su domini professionali<br>come legge,<br>medicina,<br>contabilità e<br>ingegneria.                                                                      | accuratezza | zs_cot    | No                        |
| bbh       | Testo    | Attività di<br>ragioname<br>nto avanzato<br>- Una raccolta<br>di problemi<br>impegnativi<br>che mettono<br>alla prova<br>le capacità<br>cognitive e di<br>risoluzione<br>dei problemi<br>di livello<br>superiore. | accuratezza | zs_cot    | Sì                        |



| Benchmark  | Modalità | Description                                                                                                                                 | Metriche    | Strategia | Sottoattività disponibile |
|------------|----------|---------------------------------------------------------------------------------------------------------------------------------------------|-------------|-----------|---------------------------|
| gpqa       | Testo    | Risposta a domande di fisica generale<br>- Valuta la comprensione di concetti di fisica e le relative capacità di risoluzione dei problemi. | accuratezza | zs_cot    | No                        |
| matematica | Testo    | Risoluzione di problemi matematici<br>i - Misura il ragionamento matematico su argomenti quali algebra, calcolo e problemi testuali.        | exact_match | zs_cot    | Sì                        |

| Benchmark     | Modalità | Description                                                                                                                                            | Metriche    | Strategia | Sottoattività disponibile |
|---------------|----------|--------------------------------------------------------------------------------------------------------------------------------------------------------|-------------|-----------|---------------------------|
| strong_reject | Testo    | Attività di controllo della qualità<br>- Verifica la capacità del modello di rilevare e rifiutare contenuti inappropriati, dannosi o errati.           | deflection  | zs        | Sì                        |
| IFEval        | Testo    | Valutazione che segue istruzioni - Misura la precision e con cui un modello segue le istruzion i fornite e completa le attività secondo le specifiche. | accuratezza | zs        | No                        |

| Benchmark | Modalità | Description                                                                                                                                                                                                              | Metriche | Strategia | Sottoattività disponibile |
|-----------|----------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------|-----------|---------------------------|
| gen_qa    | Testo    | Valutazione dei set di dati personalizzati<br>- Consente di utilizzare uno specifico set di dati per il benchmarking, confrontando gli output del modello con le risposte di riferimento con metriche come ROUGE e BLEU. | tutto    | gen_qa    | No                        |

| Benchmark | Modalità | Description                                                                                                                                                                                                                          | Metriche | Strategia | Sottoattività disponibile |
|-----------|----------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------|-----------|---------------------------|
| llm_judge | Testo    | LLM-as-a-Judge<br>Confronto delle preferenze: utilizza un modello Amazon Nova Judge per determinare la preferenza tra le risposte accoppiate (B rispetto a A) per i tuoi prompt, calcolando la probabilità che B sia preferito ad A. | tutto    | judge     | No                        |

| Benchmark    | Modalità               | Description                                                                                                                                                                  | Metriche | Strategia | Sottoattività disponibile |
|--------------|------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------|-----------|---------------------------|
| humaneval    | Testo                  | HumanEval - Un set di dati di riferimento progettato per valutare le capacità di generazione di codice di modelli linguistici di grandi dimensioni                           | pass@1   | zs        | No                        |
| mm_llm_judge | Multimodale (immagine) | Questo nuovo benchmark si comporta allo stesso modo del precedent e benchmark basato su testo.<br>llm_judge<br>L'unica differenza è che supporta l'inferenza delle immagini. | tutto    | judge     | No                        |

| Benchmark        | Modalità | Description                                                                                                                                                                                                                                                                                                                                                   | Metriche | Strategia | Sottoattività disponibile |
|------------------|----------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------|-----------|---------------------------|
| rubric_llm_judge | Testo    | Rubric Judge è un modello di LLM-as-a-judge valutazione avanzato basato su Amazon Nova 2.0 Lite. A differenza del <a href="#">modello di arbitro originale</a> che fornisce solo verdetti di preferenza, Rubric Judge genera dinamicamente criteri di valutazione personalizzati su misura per ogni richiesta e assegna punteggi granulari su più dimensioni. | tutto    | judge     | No                        |

| Benchmark                 | Modalità | Description                                                                                                                                                                  | Metriche    | Strategia | Sottoattività disponibile |
|---------------------------|----------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------|-----------|---------------------------|
| aime_2024                 | Testo    | AIME 2024<br>- American Invitational Mathematics Examination: problemi relativi alla verifica del ragionamento matematico avanzato e alla risoluzione dei problemi           | exact_match | zs_cot    | No                        |
| calendario_pianificazione | Testo    | Natural Plan<br>- Calendar<br>- Pianificazione delle attività, test delle attività, capacità di pianificazione per la pianificazione di riunioni su più giorni e più persone | exact_match | fs        | No                        |

Sono disponibili le seguenti sottoattività 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"
]
```

Sono disponibili le seguenti sottoattività 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"
```

```
]
```

Sono disponibili le seguenti sottoattività math:

```
MATH_SUBTASKS = [
 "algebra",
 "counting_and_probability",
 "geometry",
 "intermediate_algebra",
 "number_theory",
 "prealgebra",
 "precalculus",
]
```

## Informazioni sui parametri delle ricette

### Configurazione run

Di seguito è riportata una configurazione di tipo run generale con una spiegazione dei parametri coinvolti.

```
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:** (obbligatorio) un nome descrittivo per il processo di valutazione. Questo aiuta a identificare il tuo lavoro nella AWS console.
- **model\_type:** (obbligatorio) specifica la variante del modello Amazon Nova da utilizzare. Non modificare manualmente questo campo. Le opzioni includono:
  - `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`: (obbligatorio) il percorso del modello di base o il percorso S3 per il checkpoint post-addestrato. Le opzioni includono:
  - `nova-micro/prod`
  - `nova-lite/prod`
  - `nova-pro/prod`
  - `nova-lite-2/prod`
  - (Percorso S3 per il checkpoint post-addestrato) `s3://<escrow bucket>/<job id>/outputs/checkpoints`
- `replicas`: (obbligatorio) il numero di istanze di calcolo da utilizzare per l'addestramento distribuito. È necessario impostare questo valore su 1, perché la modalità multinodo non è supportata.
- `data_s3_path`: (obbligatorio) il percorso S3 del set di dati di input. Lascia vuoto questo parametro, se non in caso di utilizzo di una ricetta Bring Your Own Dataset o LLM-as-a-judge.
- `output_s3_path`: (obbligatorio) il percorso S3 per archiviare gli artefatti di valutazione dell'output. Il bucket S3 di output deve essere creato dallo stesso account che crea il processo.
- `mlflow_tracking_uri`: (Opzionale) ARN del server di MLflow tracciamento per tracciare MLFlow esecuzioni/esperimenti. Assicurati di avere il permesso di accedere al server di tracciamento dal SageMaker ruolo di esecuzione AI

## Configurazione evaluation

Di seguito è riportata una configurazione di tipo evaluation del modello con una spiegazione dei parametri coinvolti.

```
evaluation:
 task: mmlu
 strategy: zs_cot
 subtask: mathematics
 metric: accuracy
```

- `task`: (obbligatorio) specifica il benchmark o l'attività di valutazione da utilizzare.

Elenco delle attività supportate:

- `mmlu`
- `mmlu_pro`

- bbh
- gpqa
- matematica
- strong\_reject
- gen\_qa
- ifeval
- llm\_judge
- humaneval
- mm\_llm\_judge
- rubric\_llm\_judge
- aime\_2024
- calendario\_programmazione
- humaneval
- **strategy:** (obbligatorio) definisce l'approccio di valutazione:
  - **zs\_cot:** Zero-shot Chain-of-Thought - Un approccio per suggerire modelli linguistici di grandi dimensioni che incoraggia il ragionamento senza richiedere esempi espliciti. step-by-step
  - **zs:** Zero-shot - Un approccio per risolvere un problema senza esempi di addestramento precedenti.
  - **gen\_qa:** una strategia specifica per ricette di tipo Bring Your Own Dataset.
  - **judge:** una strategia specifica per Amazon Nova LLM come Judge e mm\_llm\_judge.
- **subtask:** (facoltativo e rimovibile) specifica una determinata sottoattività per alcune attività di valutazione. Rimuovila dalla tua ricetta se la tua attività non include sottoattività.
- **metric:** (obbligatorio) la metrica di valutazione da utilizzare.
  - **accuracy:** percentuale di risposte corrette
  - **exact\_match:** (per il benchmark math), restituisce la velocità con cui le stringhe previste nell'input corrispondono esattamente ai loro riferimenti.
  - **deflection:** (per il benchmark strong\_reject), restituisce la deviazione relativa rispetto al modello di base e la differenza nelle metriche di significatività.
  - **pass@1:** (per il benchmark humaneval) è una metrica utilizzata per misurare la percentuale di casi in cui la previsione con la massima affidabilità del modello corrisponde alla risposta corretta.

- Per un benchmark Bring Your Own Dataset e `gen_qa`, restituisce le seguenti metriche:
  - `rouge1`: misura la sovrapposizione di unigrammi (parole singole) tra il testo generato e quello di riferimento.
  - `rouge2`: misura la sovrapposizione di bigrammi (due parole consecutive) tra il testo generato e quello di riferimento.
  - `rougeL`: misura la sottosequenza comune più lunga tra testi, tenendo conto di lacune nella corrispondenza.
  - `exact_match`: punteggio binario (0 oppure 1) che indica se il testo generato corrisponde esattamente al testo di riferimento, carattere per carattere.
  - `quasi_exact_match`: simile alla corrispondenza esatta, ma meno rigida, in genere ignora le differenze tra maiuscole e minuscole, punteggiatura e spazi.
  - `f1_score`: media armonica di precisione e richiamo, che misura la sovrapposizione di parole tra le risposte previste e quelle di riferimento.
  - `f1_score_quasi`: simile a `f1_score`, ma con una corrispondenza meno rigida, utilizza un confronto di testo normalizzato che ignora differenze minori.
  - `bleu`: misura la precisione delle corrispondenze in n-grammi tra il testo generato e quello di riferimento, comunemente utilizzate nella valutazione delle traduzioni.
- `Inoltremm_llm_judge`, porta il tuo `llm_judge` benchmark personale per il set di dati, restituisce le seguenti metriche:
  - `a_scores`: numero di vittorie per `response_A` nei passaggi di valutazione avanti e indietro.
  - `a_scores_stderr`: errore standard di `response_A scores` nei giudizi a coppie.
  - `b_scores`: numero di vittorie per `response_B` nei passaggi di valutazione avanti e indietro.
  - `b_scores_stderr`: errore standard di `response_B scores` nei giudizi a coppie.
  - `ties`: numero di giudizi in cui `response_A` e `response_B` sono valutati in modo uguale.
  - `ties_stderr`: errore standard di `ties` nei giudizi a coppie.
  - `inference_error`: numero di giudizi che non è stato possibile valutare correttamente.
  - `inference_error_stderr`: errore standard degli errori di inferenza nei i giudizi.
  - `score`: punteggio aggregato basato sulle vittorie nei passaggi avanti e indietro per `response_B`.
  - `score_stderr`: errore standard del punteggio aggregato nei giudizi a coppie.
  - `winrate`: la probabilità che `response_B` venga preferito rispetto a `response_a` calcolato

- `lower_rate`: limite inferiore (percentile 2,5) del tasso di successo stimato derivante dal campionamento bootstrap.

## Configurazione inference

Di seguito è riportata una configurazione di tipo inference con una spiegazione dei parametri coinvolti. Tutti i parametri sono opzionali:

```
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`: il numero massimo di token da generare. Deve essere un numero intero.
- `top_k`: il numero di token con la più alta probabilità da considerare. Deve essere un numero intero.
- `top_p`: la soglia di probabilità cumulativa per il campionamento tramite token. Deve essere un valore decimale compreso tra 0,0 e 1,0, entrambi inclusi.
- `temperature`: casualità nella selezione dei token. Valori più grandi introducono una maggiore casualità. Usa 0 per rendere deterministici i risultati. Deve essere un valore decimale minimo pari a 0.
- `top_logprobs`: Il numero di migliori logprobs da restituire nella risposta di inferenza. Questo valore deve essere un numero intero compreso tra 0 e 20. I logprobs contengono i token di output considerati e le probabilità di registro di ogni token di output restituito nel contenuto del messaggio.
- `reasoning_effort`: controlla il comportamento di ragionamento per modelli in grado di ragionare. Imposta `reasoning_effort` solo quando `model_type` specifica un modello in grado di ragionare (attualmente). `amazon.nova-2-lite-v1:0:256k` Le opzioni disponibili sono `null` (valore predefinito se non impostato; disabilita il ragionamento), o. `low high`

Per `humaneval` è consigliabile la configurazione inference seguente:

```
inference:
 top_k: 1
 max_new_tokens: 1600
```

```
temperature: 0.0
```

## MLFlow configurazione

Di seguito è riportata una MLFlow configurazione e una spiegazione dei parametri coinvolti. Tutti i parametri sono opzionali:

```
run:
 mlflow_tracking_uri: ""
 mlflow_experiment_name: ""
 mlflow_run_name: ""
```

- `mlflow_tracking_uri`: (Facoltativo) La posizione del server di MLflow tracciamento (necessaria solo su SMHP)
- `mlflow_experiment_name`: (Facoltativo) Nome dell'esperimento per raggruppare le esecuzioni ML correlate
- `mlflow_run_name`: (Facoltativo) Nome personalizzato per un corso di formazione specifico all'interno di un esperimento

## Esempi di ricette di valutazione

Amazon Nova offre quattro tipi di ricette di valutazione, disponibili nell' [GitHub](#) archivio delle SageMaker HyperPod ricette.

### Ricette di benchmark testuali generali

Queste ricette consentono di valutare le funzionalità fondamentali dei modelli Amazon Nova attraverso una suite completa di benchmark di solo testo. Sono fornite nel formato `xxx_general_text_benchmark_eval.yaml`.

### Ricette di benchmark Bring Your Own Dataset

Queste ricette consentono di utilizzare un set di dati personalizzato per il benchmarking e confrontare i risultati del modello con risposte di riferimento utilizzando diversi tipi di metriche. Sono fornite nel formato `xxx_bring_your_own_dataset_eval.yaml`.

Di seguito sono riportati i requisiti per Bring Your Own Data:

- Requisiti relativi al formato dei file
  - È necessario includere un singolo file `gen_qa.jsonl` contenente esempi di valutazione.

- Il set di dati deve essere caricato in una posizione S3 a cui SageMaker Training Job possa accedervi.
- Il file deve seguire il formato dello schema richiesto per un set di dati di domande e risposte generico.
- Requisiti del formato dello schema - Ogni riga del file JSONL deve essere un oggetto JSON con i campi seguenti:
  - `query`: (obbligatorio) stringa contenente la domanda o l'istruzione che richiede una risposta
  - `response`: (obbligatorio) stringa contenente l'output del modello previsto
  - `system`: (facoltativo) stringa contenente il prompt di sistema che imposta il comportamento, il ruolo o la personalità del modello di intelligenza artificiale prima che elabori la query
  - `metadata`: (Facoltativo) Stringa contenente i metadati associati alla voce a scopo di etichettatura.

Ecco un esempio di inserimento Bring Your Own Dataset

```
{
 "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"
}
```

Per utilizzare un set di dati personalizzato, modifica la ricetta di valutazione con i seguenti campi obbligatori, senza modificare alcun contenuto:

`evaluation:`



```
task: gen_qa
strategy: gen_qa
metric: all
```

Si applicano le limitazioni seguenti:

- È consentito un solo file JSONL per valutazione.
- Il file deve seguire rigorosamente lo schema definito.
- Limite di lunghezza del contesto: per ogni campione del set di dati, la lunghezza del contesto (inclusi i prompt di interrogazione di sistema +) deve essere inferiore a 3,5 k.

### Ricette di benchmark Nova LLM-as-a-judge

Amazon Nova LLM-as-a-judge è una funzionalità di valutazione del modello che consente ai clienti di confrontare la qualità delle risposte di un modello con una risposta del modello di base su un set di dati personalizzato. [Include un set di dati con prompt, risposte di base e risposte sfidanti e utilizza un modello Amazon Nova Judge per fornire una metrica della percentuale di vittorie basata sulla probabilità di Bradley-Terry con confronti a coppie.](#)

Le ricette sono fornite nel formato `xxx_llm_judge_eval.yaml`.

Di seguito sono riportati i requisiti per LLM-as-a-judge:

- Requisiti relativi al formato dei file
  - È necessario includere un singolo file `llm_judge.jsonl` contenente esempi di valutazione. Il nome del file deve essere `llm_judge.jsonl`.
  - [Il set di dati deve essere caricato in una posizione S3 a cui AI RIG può accedere. SageMaker SageMaker HyperPod](#)
  - Il file deve seguire il formato dello schema richiesto per il set di dati `llm_judge.jsonl`.
  - Il set di dati di input deve garantire che tutti i record abbiano una lunghezza di contesto inferiore a 12.000.
- Requisiti del formato dello schema - Ogni riga del file JSONL deve essere un oggetto JSON con i campi seguenti:
  - `prompt`: (obbligatorio) una stringa contenente il prompt per la risposta generata.
  - `response_A`: una stringa contenente la risposta di base.
  - `response_B`: una stringa contenente la risposta alternativa da confrontare con la risposta di base.

## Ecco un esempio di inserimento 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."
}
```

Per utilizzare un set di dati personalizzato, modifica la ricetta di valutazione con i seguenti campi obbligatori, senza modificare alcun contenuto:

```
evaluation:
 task: llm_judge
 strategy: judge
 metric: all
```

Si applicano le limitazioni seguenti:

- È consentito un solo file JSONL per valutazione.
- Il file deve seguire rigorosamente lo schema definito.

- I modelli Amazon Nova Judge sono gli stessi per tutte le specifiche delle famiglie di modelli (ovvero Lite, Micro e Pro).
- Al momento i modelli Judge personalizzati non sono supportati.
- Limite di lunghezza del contesto: per ogni campione del set di dati, la lunghezza del contesto (inclusi i prompt di interrogazione di sistema +) deve essere inferiore a 7k.

Nova LLM come giudice per le ricette di riferimento multimodali (immagini)

Nova LLM Judge for multi-modal (immagine), abbreviazione di Amazon Nova MM\_LLM Judge, è una funzionalità di valutazione del modello che consente di confrontare la qualità delle risposte di un modello con le risposte di un modello di base utilizzando un set di dati personalizzato. [Accetta un set di dati contenente prompt, risposte di base e risposte sfidanti e immagini sotto forma di stringa codificata in Base64, quindi utilizza un modello Amazon Nova Judge per fornire una metrica del tasso di successo basata sulla probabilità di Bradley-Terry attraverso confronti a coppie.](#) Formato della ricetta: `xxx_mm_llm_judge_eval.yaml`.

Requisiti dei set di dati Nova LLM

Formato del file:

- Singolo file `mm_llm_judge.jsonl` contenente esempi di valutazione. Il nome del file deve essere esatto. `llm_judge.jsonl`
- È necessario caricare il set di dati in una posizione S3 a cui SageMaker Training Jobs possa accedervi.
- Il file deve seguire il formato dello schema richiesto per il set di dati `mm_llm_judge`.
- Il set di dati di input dovrebbe garantire che tutti i record abbiano una lunghezza di contesto inferiore a 12 k, escluso l'attributo dell'immagine.

Formato dello schema - Ogni riga del file `.jsonl` deve essere un oggetto JSON con i campi seguenti.

- Campi obbligatori.

`prompt`: stringa contenente il prompt per la risposta generata.

`images`: Array contenente un elenco di oggetti con attributi di dati (i valori sono stringhe di immagine codificate in Base64).

`response_A`: stringa contenente la risposta di base.

`response_B`: stringa contenente la risposta alternativa da confrontare con la risposta di base.

## Esempio di inserimento

Per motivi di leggibilità, l'esempio seguente include nuove righe e rientri, ma nel set di dati effettivo, ogni record deve trovarsi su una sola riga.

```
{
 "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",
}
```

Per utilizzare un set di dati personalizzato, modifica la ricetta di valutazione con i seguenti campi obbligatori, senza modificare alcun contenuto:

```
evaluation:
 task: mm_llm_judge
 strategy: judge
 metric: all
```

## Limitazioni

- È consentito un solo file `.jsonl` per valutazione.
- Il file deve seguire rigorosamente lo schema definito.
- I modelli Nova MM Judge supportano solo il riferimento alle immagini.
- I modelli Nova MM Judge sono gli stessi per tutte le specifiche di Amazon Nova Lite.
- Attualmente i modelli Judge personalizzati non sono supportati.
- L'URI di immagine Amazon S3 non è supportato.
- Il set di dati di input dovrebbe garantire che tutti i record abbiano una lunghezza di contesto inferiore a 12 k, escluso l'attributo `images`.

## Giudice basato sulla rubrica

Rubric Judge è un modello di LLM-as-a-judge valutazione avanzato basato su Amazon Nova 2.0 Lite. A differenza del [modello di arbitro originale](#) che fornisce solo verdetti di preferenza (A>B, B>A o pareggio), Rubric Judge genera dinamicamente criteri di valutazione personalizzati su misura per ogni richiesta e assegna punteggi granulari su più dimensioni.

### Funzionalità chiave:

- Generazione dinamica di criteri: crea automaticamente dimensioni di valutazione pertinenti in base alla richiesta di input
- Punteggio ponderato: assegna dei pesi di importanza a ciascun criterio in base alla loro importanza relativa
- Valutazione granulare: fornisce punteggi dettagliati su base binaria (vero/falso) o su scala (1-5) per ogni criterio
- Metriche di qualità: calcola punteggi di qualità continui (scala 0-1) che quantificano l'entità delle differenze tra le risposte

### Criterio di esempio generato dal modello:

```
price_validation:
 description: "The response includes validation to ensure price is a positive value."
 type: "scale"
 weight: 0.3
```

Il modello valuta entrambe le risposte rispetto a tutti i criteri generati, quindi utilizza questi punteggi a livello di criterio per determinare la preferenza finale.

## Argomenti

- [Configurazione della ricetta](#)
- [Formato del set di dati di input](#)
- [Risultato della valutazione](#)
- [Supporto del modello di ragionamento](#)

## Configurazione della ricetta

### Ricetta Rubric Judge

Abilita Rubric Judge task: `rubric_llm_judge` impostando nella tua ricetta:

```
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)

```

Ricetta originale LLM as a Judge (per confronto)

Il modello di giudice originale utilizzatask: 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)

```

Formato del set di dati di input

Il formato del set di dati di input è identico al modello [originale del giudice](#):

Campi obbligatori:

- **prompt**: Stringa contenente il prompt di input e le istruzioni
- **response\_A**: Stringa contenente l'output del modello di base
- **response\_B**: Stringa contenente l'output del modello personalizzato

Set di dati di esempio (formato JSONL):

```
{"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."}
```

Requisiti di formato:

- Ogni voce deve essere un oggetto JSON a riga singola
- Separa le voci con nuove righe
- Segui l'esatta denominazione dei campi, come mostrato negli esempi

Risultato della valutazione

Struttura di output

Rubric Judge produce metriche di valutazione migliorate rispetto al modello di giudice originale:

```
{
```



```

"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"
}
}

```

## Nuove metriche in Rubric Judge

Le seguenti sei metriche sono esclusive di Rubric Judge e forniscono una valutazione granulare della qualità:

| Metrica                 | Description                                                                                                                                                                                                                                       |
|-------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| punteggio_ponderato_A   | Punteggio di qualità medio normalizzato per Response_a in base a tutti i criteri di valutazione generati dal modello. I punteggi sono ponderati in base all'importanza del criterio e normalizzati su una scala 0-1 (più alto = migliore qualità) |
| Weighted_score_a_stderr | Errore standard della media per Weighted_score_a, che indica l'incertezza statistica                                                                                                                                                              |
| Punteggio_ponderato_B   | Punteggio di qualità medio normalizzato per Response_b in tutti i criteri di valutazione generati dal modello. I punteggi sono ponderati in base all'importanza del criterio e normalizzati su una scala 0-1 (più alto = migliore qualità)        |
| Weighted_score_b_stderr | Errore standard della media per Weighted_score_b, che indica l'incertezza statistica                                                                                                                                                              |
| score_margin            | Differenza tra i punteggi ponderati (calcolati come Weighted_score_A - Weighted_score_b). Intervallo: da -1,0 a 1,0. Positivo = response_a è migliore; negativo = response_B è migliore; vicino allo zero = qualità simile                        |
| score_margin_stderr     | Errore standard della media di score_margin, che indica l'incertezza nella misurazione della differenza di qualità                                                                                                                                |

### Comprensione delle metriche dei punteggi ponderati

Scopo: i punteggi ponderati forniscono misurazioni continue della qualità che completano i verdetti sulle preferenze binarie, consentendo una visione più approfondita delle prestazioni del modello.

## Principali differenze rispetto al giudice originale:

- Giudice originale: emette solo preferenze discrete ( $A > B$ ,  $B > A$ ,  $A = B$ )
- Rubric Judge: emette sia le preferenze che i punteggi di qualità continui (scala 0-1) in base a criteri personalizzati

## Interpretazione di `score_margin`:

- `score_margin = -0.128`: Response\_B ha ottenuto 12,8 punti percentuali in più rispetto a Response\_a
- `|score_margin| < 0.1`: Differenza di qualità ridotta (decisione ravvicinata)
- `|score_margin| > 0.2`: Chiara differenza di qualità (decisione sicura)

## Casi d'uso:

- Miglioramento del modello: identifica le aree specifiche in cui il tuo modello ha prestazioni inferiori
- Quantificazione della qualità: misura l'entità dei divari prestazionali, non solo i rapporti win/loss
- Valutazione della fiducia: distinguere tra decisioni ravvicinate e chiare differenze di qualità

### Important

I verdetti finali si basano ancora sulle etichette di preferenza esplicite del modello giudicante per preservare un ragionamento olistico e garantire un'adeguata mitigazione dei pregiudizi di posizione attraverso la valutazione. forward/backward I punteggi ponderati servono come strumenti di osservabilità, non come sostituti del verdetto primario.

## Metodologia di calcolo

I punteggi ponderati vengono calcolati attraverso il seguente processo:

- Estrai i dati dei criteri: analizza l'output YAML del giudice per estrarre i punteggi e i pesi dei criteri
- Normalizza i punteggi:
  - Criteri basati sul tipo di scala (1-5): normalizza a 0-1 calcolando  $(\text{score} - 1) / 4$
  - Criteri binari (vero/falso): converti in 1,0/0,0

- Applica pesi: moltiplica ogni punteggio normalizzato per il relativo peso del criterio
- Aggregato: somma tutti i punteggi ponderati per ogni risposta
- Calcola il margine: calcola  $\text{score\_margin} = \text{weighted\_score\_A} - \text{weighted\_score\_B}$

Esempio: se `response_a` ha una somma ponderata di 0,65 e `Response_b` ha 0,78, `score_margin` sarebbe -0,13, indicando che `response_b` è di 13 punti percentuali superiore in termini di qualità in tutti i criteri ponderati.

## Supporto del modello di ragionamento

Il supporto del modello di ragionamento consente la valutazione con modelli Amazon Nova compatibili con il ragionamento che eseguono un ragionamento interno esplicito prima di generare risposte finali. Questa funzionalità utilizza il controllo a livello di API tramite il `reasoning_effort` parametro per abilitare o disabilitare dinamicamente la funzionalità di ragionamento, migliorando potenzialmente la qualità della risposta per attività analitiche complesse.

### Modelli supportati:

- `amazon.nova-2-lite-v 1:0:256k`

## Configurazione della ricetta

Abilita il ragionamento aggiungendo il `reasoning_effort` parametro alla `inference` sezione della tua ricetta:

```
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)

```

### Utilizzo del parametro `reasoning_effort`

Il `reasoning_effort` parametro controlla il comportamento di ragionamento per i modelli in grado di ragionare.

#### Prerequisiti:

- Compatibilità dei modelli: impostata `reasoning_effort` solo quando `model_type` specifica un modello in grado di ragionare (attualmente) `amazon.nova-2-lite-v1:0:256k`
- Gestione degli errori: l'utilizzo `reasoning_effort` con modelli non supportati avrà esito negativo con `ConfigValidationError: "Reasoning mode is enabled but model '{model_type}' does not support reasoning. Please use a reasoning-capable model or disable reasoning mode."`

#### Opzioni disponibili:

| Opzione                         | Comportamento                         | Limite di token | Caso d'uso                                              |
|---------------------------------|---------------------------------------|-----------------|---------------------------------------------------------|
| null (impostazione predefinita) | Disattiva la modalità di ragionamento | N/D             | Valutazione standard senza sovraccarico di ragionamento |

| Opzione | Comportamento                          | Limite di token                                 | Caso d'uso                                                                         |
|---------|----------------------------------------|-------------------------------------------------|------------------------------------------------------------------------------------|
| low     | Consente il ragionamento con vincoli   | 4.000 token per il ragionamento interno         | Scenari che richiedono o un ragionamento conciso; ottimizza velocità e costi       |
| high    | Consente il ragionamento senza vincoli | Nessun limite simbolico al ragionamento interno | Problemi complessi che richiedono analisi e step-by-step ragionamenti approfonditi |

### Quando abilitare il ragionamento

Usa la modalità di ragionamento (**lowmedium, ohigh**) per:

- Compiti complessi di risoluzione di problemi (matematica, puzzle logici, programmazione)
- Domande analitiche in più fasi che richiedono un ragionamento intermedio
- Attività in cui spiegazioni o riflessioni dettagliate migliorano la precisione step-by-step
- Scenari in cui la qualità della risposta è prioritaria rispetto alla velocità

Utilizza la modalità non ragionamento (parametro di omissione) per:

- Domande e risposte semplici o domande basate sui fatti
- Attività di scrittura creativa
- Quando i tempi di risposta più rapidi sono fondamentali
- Analisi comparativa delle prestazioni in cui è necessario escludere il sovraccarico di ragionamento
- L'ottimizzazione dei costi quando il ragionamento non migliora le prestazioni delle attività

### Risoluzione dei problemi

Errore: «La modalità di ragionamento è abilitata ma il modello non supporta il ragionamento»

Causa: il `reasoning_effort` parametro è impostato su un valore diverso da nullo, ma quello specificato `model_type` non supporta il ragionamento.

## Risoluzione:

- Verifica che il tipo di modello sia `amazon.nova-2-lite-v1:0:256k`
- Se utilizzi un modello diverso, passa a un modello in grado di ragionare o rimuovi il `reasoning_effort` parametro dalla tua ricetta

## Avvio di un processo di valutazione

Di seguito viene fornita una configurazione consigliata del tipo di istanza di valutazione e del tipo di modello:

```
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_48xl_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]

```

Dovrebbe essere anche possibile visualizzare lo stato del processo tramite la console del cluster Amazon EKS.

## Accesso e analisi dei risultati di valutazione

Una volta completato correttamente il processo di valutazione, è possibile accedere ai risultati e analizzarli utilizzando le informazioni contenute in questa sezione. In base al valore `output_s3_path` (ad esempio `s3://output_path/`) definito nella ricetta, la struttura di output è la seguente:

```

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]

```

I risultati delle metriche vengono archiviati nella posizione di output S3 `s3://output_path/job_name/eval-result/result-timestamp.json` specificata.



I risultati di Tensorboard vengono archiviati nel percorso S3 `s3://output_path/job_name/eval-tensorboard-result/eval/event.out.tfevents.epoch+ip`.

Tutti gli output di inferenza, ad eccezione di `llm_judge` e `strong_reject`, vengono archiviati nel percorso S3 `s3://output_path/job_name/eval-result/details/model/taskname.parquet`.

Per `gen_qa`, il file `inference_output.jsonl` contiene i seguenti campi per ogni oggetto JSON:

- `prompt` - Il prompt finale inviato al modello
- `inference` - L'output di inferenza non elaborato del modello
- `gold` - La risposta target dal set di dati di input
- `metadata` - La stringa di metadati del set di dati di input, se fornita

Per visualizzare le metriche di valutazione in Tensorboard, completa la seguente procedura:

1. Passa a AI SageMaker Tensorboard.
2. Seleziona Cartelle S3.
3. Aggiungi il percorso della cartella S3, ad esempio `s3://output_path/job-name/eval-tensorboard-result/eval`.
4. Attendi il completamento della sincronizzazione.

Sono disponibili le visualizzazioni delle serie temporali, degli scalari e del testo.

È preferibile seguire le best practice seguenti:

- Mantieni i percorsi di output organizzati per modello e tipo di benchmark.
- Mantieni convenzioni di denominazione coerenti per semplificare il monitoraggio.
- Salva i risultati estratti in una posizione sicura.
- Monitora lo stato di TensorBoard sincronizzazione per il corretto caricamento dei dati.

È possibile trovare i log degli errori di SageMaker HyperPod lavoro nel gruppo `/aws/sagemaker/Clusters/cluster-id` di CloudWatch log.

## Formato di output della probabilità logaritmica

Se `top_logprobs` configurato nelle impostazioni di inferenza, l'output di valutazione include le probabilità di registro a livello di token nei file parquet. Ogni posizione del token contiene un dizionario dei migliori token candidati con le relative probabilità di registro nella seguente struttura:

```
{
 "Ġint": {"logprob_value": -17.8125, "decoded_value": " int"},
 "Ġthe": {"logprob_value": -2.345, "decoded_value": " the"}
}
```

Ogni voce del token contiene:

- `logprob_value`: Il valore di probabilità logaritmica per il token
- `decoded_value`: La rappresentazione di stringa decodificata leggibile dall'uomo del token

Il token tokenizer non elaborato viene utilizzato come chiave del dizionario per garantire l'unicità, fornendo al contempo un'interpretazione leggibile. `decoded_value`

## Valutazione RFT

### Note

La valutazione tramite funzioni di ricompensa remota nel tuo AWS ambiente è disponibile solo se sei cliente di Amazon Nova Forge.

### Important

Il campo `rl_env` di configurazione viene utilizzato esclusivamente per la valutazione, non per la formazione. Durante la formazione, si configurano le funzioni di ricompensa utilizzando l'infrastruttura `reward_lambda_arn` (a turno singolo) o BYOO con `rollout.delegate: true` (turno multiplo).

## Cos'è la valutazione RFT?

RFT Evaluation consente di valutare le prestazioni del modello utilizzando funzioni di ricompensa personalizzate prima, durante o dopo la formazione di reinforcement learning. A differenza delle

valutazioni standard che utilizzano metriche predefinite, RFT Evaluation consente di definire criteri di successo personalizzati tramite una funzione Lambda che assegna un punteggio agli output del modello in base ai requisiti specifici.

Perché effettuare una valutazione con RFT?

La valutazione è fondamentale per determinare se il processo di messa a punto di RL presenta:

- Migliore allineamento del modello con il caso d'uso specifico e i valori umani
- Funzionalità del modello mantenute o migliorate per le attività chiave
- Ha evitato effetti collaterali indesiderati come riduzione della fattualità, aumento della verbosità o riduzione delle prestazioni in altre attività
- Hai soddisfatto i criteri di successo personalizzati definiti dalla tua funzione di ricompensa

Quando utilizzare la valutazione RFT

Utilizza RFT Evaluation in questi scenari:

- Prima della formazione RFT: stabilisci le metriche di base sul tuo set di dati di valutazione
- Durante l'allenamento RFT: monitora i progressi dell'allenamento con punti di controllo intermedi
- Dopo la formazione RFT: verifica che il modello finale soddisfi i tuoi requisiti
- Confronto tra modelli: valuta più versioni del modello utilizzando criteri di ricompensa coerenti

#### Note

Usa RFT Evaluation quando hai bisogno di metriche personalizzate e specifiche del dominio. Per una valutazione generica (precisione, perplessità, BLEU), utilizzate metodi di valutazione standard.

Argomenti

- [Requisiti per il formato dei dati](#)
- [Preparazione della ricetta di valutazione](#)
- [Funzioni di ricompensa preimpostate](#)
- [Creazione della tua funzione di ricompensa](#)
- [autorizzazioni IAM](#)

- [Esecuzione del processo di valutazione](#)
- [Comprensione dei risultati della valutazione](#)

Requisiti per il formato dei dati

Struttura dei dati di input

I dati di input di valutazione RFT devono seguire il formato OpenAI Reinforcement Fine-Tuning. Ogni esempio è un oggetto JSON contenente:

- `messages`: serie di turni di conversazione con ruoli `system` `user`
- Altri metadati opzionali, ad esempio `reference_answer`

Esempio di formato dei dati

L'esempio seguente mostra il formato richiesto:

```
{
 "messages": [
 {
 "role": "user",
 "content": [
 {
 "type": "text",
 "text": "Solve for x. Return only JSON like {\"x\": <number>}. Equation: 2x + 5 = 13"
 }
]
 }
],
 "reference_answer": {
 "x": 4
 }
}
```

Limitazioni attuali

Le seguenti limitazioni si applicano alla valutazione RFT:

- Solo testo: non sono supportati input multimodali (immagini, audio, video)

- Conversazioni a turno singolo: supporta solo messaggi utente singoli (non dialoghi a più turni)
- Formato JSON: i dati di input devono essere in formato JSONL (un oggetto JSON per riga)
- Risultati del modello: la valutazione viene eseguita sui completamenti generati dal modello specificato

## Preparazione della ricetta di valutazione

### Esempio di configurazione della ricetta

L'esempio seguente mostra una ricetta di valutazione RFT completa:

```
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>
```

## Funzioni di ricompensa preimpostate

Due funzioni di ricompensa preimpostate (`prime_code` e `prime_math`) sono disponibili come layer Lambda per una facile integrazione con le funzioni RFT Lambda.

### Panoramica di

Queste funzioni preimpostate forniscono funzionalità di valutazione per: out-of-the-box

- `prime_code`: generazione di codice e valutazione della correttezza
- `prime_math`: ragionamento matematico e valutazione della risoluzione dei problemi

## Configurazione rapida

Per utilizzare le funzioni di ricompensa preimpostate:

1. [Scarica il layer Lambda dalle versioni nova-custom-eval-sdk](#)
2. Pubblica il layer Lambda utilizzando la CLI: AWS

```
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. Aggiungi il layer alla tua funzione Lambda in AWS Console (seleziona il layer `preset-function-layer` dal livello personalizzato e aggiungi anche `AWSSDKPandas-Python 312` per le dipendenze `numpy`)
4. Importa e usa nel tuo codice Lambda:

```
from prime_code import compute_score # For code evaluation
from prime_math import compute_score # For math evaluation
```

## funzione `prime_code`

Scopo: valuta le attività di generazione del codice Python eseguendo codice in base a casi di test e misurando la correttezza.

Esempio di formato del set di dati di input tratto dalla valutazione:

```
{"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"]}}
```

Caratteristiche principali:

- Estrazione automatica del codice dai blocchi di codice markdown
- Rilevamento delle funzioni e test basati sulle chiamate
- Esecuzione di test case con protezione dal timeout
- Convalida della sintassi e controlli di compilazione
- Segnalazione dettagliata degli errori con traceback

funzione prime\_math

Scopo: valuta le capacità di ragionamento matematico e di risoluzione dei problemi con supporto matematico simbolico.

Formato di input:

```
{"messages":[{"role":"user","content":"What is the derivative of x^2 + 3x?."}], "reference_answer":"2*x + 3"}
```

Caratteristiche principali:

- Valutazione matematica simbolica utilizzando SymPy
- Formati di risposta multipli (LaTeX, testo semplice, simbolico)
- Controllo matematico dell'equivalenza
- Normalizzazione e semplificazione delle espressioni

Best practice

Segui queste best practice quando utilizzi le funzioni di ricompensa preimpostate:

- Usa i tipi di dati appropriati nei casi di test (numeri interi contro stringhe, booleani vs «True»)
- Fornisci firme funzionali chiare nei problemi di codice
- Includi casi limite negli input di test (zero, numeri negativi, input vuoti)
- Formatta le espressioni matematiche in modo coerente nelle risposte di riferimento
- Testa la tua funzione di ricompensa con dati di esempio prima dell'implementazione

Creazione della tua funzione di ricompensa

Lambda ARN

È necessario fare riferimento al seguente formato per l'ARN Lambda:

```
"arn:aws:lambda:*:*:function:*SageMaker*"
```

Se la Lambda non dispone di questo schema di denominazione, il processo avrà esito negativo con questo errore:

```
[ERROR] Unexpected error: lambda_arn must contain one of: ['SageMaker', 'sagemaker', 'Sagemaker'] when running on SMHP platform (Key: lambda_arn)
```

Struttura della funzione Lambda

La tua funzione Lambda riceve batch di output del modello e restituisce punteggi di ricompensa. Di seguito è riportato un esempio di implementazione:

```
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
```

## Formato di richiesta Lambda

La tua funzione Lambda riceve i dati in questo formato:

```
[
 {
 "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

La struttura dei messaggi include l'`contentarray` annidato, corrispondente al formato dei dati di input. L'ultimo messaggio con ruolo `nova_assistant` contiene la risposta generata dal modello.

## Formato di risposta Lambda

La funzione Lambda deve restituire dati in questo formato:

```

[
 {
 "id": "sample-001",
 "aggregate_reward_score": 0.75,
 "metrics_list": [

```

```

 {
 "name": "accuracy",
 "value": 0.85,
 "type": "Metric"
 },
 {
 "name": "fluency",
 "value": 0.90,
 "type": "Reward"
 }
]
}
]
```

### Campi di risposta:

- **id**: Deve corrispondere all'ID del campione di input
- **aggregate\_reward\_score**: Punteggio complessivo (in genere da 0,0 a 1,0)
- **metrics\_list**: Serie di metriche individuali con:
  - **name**: identificatore metrico (ad es. «precisione», «fluidità»)
  - **value**: Punteggio metrico (in genere da 0,0 a 1,0)
  - **type**: «Metrico» (per la rendicontazione) o «Ricompensa» (utilizzato nella formazione)

### autorizzazioni IAM

#### Autorizzazioni richieste

Il tuo ruolo di esecuzione SageMaker AI deve disporre delle autorizzazioni per richiamare la tua funzione Lambda. Aggiungi questa policy al tuo ruolo di esecuzione dell' SageMaker IA:

```

{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Effect": "Allow",
 "Action": [
 "lambda:InvokeFunction"
],
 "Resource": "arn:aws:lambda:region:account-id:function:function-name"
 }
]
}
```

```
]
}
```

## Ruolo di esecuzione Lambda

Il ruolo di esecuzione della tua funzione Lambda richiede le autorizzazioni di esecuzione Lambda di base:

```
{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Effect": "Allow",
 "Action": [
 "logs:CreateLogGroup",
 "logs:CreateLogStream",
 "logs:PutLogEvents"
],
 "Resource": "arn:aws:logs:*:*:*"
 }
]
}
```

Autorizzazioni aggiuntive: se la tua funzione Lambda accede AWS ad altri servizi (ad esempio, Amazon S3 per i dati di riferimento, DynamoDB per la registrazione), aggiungi tali autorizzazioni al ruolo di esecuzione Lambda.

## Esecuzione del processo di valutazione

### 1. Prepara i tuoi dati

- Formattate i dati di valutazione in base ai requisiti di formato dei dati
- Carica il tuo file JSONL su Amazon S3: `s3://your-bucket/eval-data/eval_data.jsonl`

### 2. Configura la tua ricetta

Aggiorna la ricetta di esempio con la tua configurazione:

- Imposta `model_name_or_path` la posizione del modello
- Imposta `lambda_arn` sulla funzione di ricompensa ARN

- Imposta `output_s3_path` la posizione di uscita desiderata
- Regola `inference` i parametri secondo necessità

Salva la ricetta con nome `rft_eval_recipe.yaml`

### 3. Esegui la valutazione

Esegui il lavoro di valutazione utilizzando il notebook fornito: Notebook di [valutazione del modello Nova](#)

### 4. Monitora i progressi

Monitora il tuo lavoro di valutazione tramite:

- SageMaker Console AI: controlla lo stato e i registri del lavoro
- CloudWatch Registri: visualizza i registri di esecuzione dettagliati
- Lambda Logs: problemi relativi alla funzione di ricompensa di debug

## Comprensione dei risultati della valutazione

### Formato di output

Il processo di valutazione restituisce i risultati alla posizione Amazon S3 specificata in formato JSONL. Ogni riga contiene i risultati della valutazione per un campione:

```
{
 "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

L'RFT Evaluation Job Output è identico al formato Lambda Response. Il servizio di valutazione analizza la risposta della funzione Lambda senza modifiche, garantendo la coerenza tra i calcoli delle ricompense e i risultati finali.

## Interpretazione dei risultati

### Punteggio di ricompensa aggregato:

- Intervallo: in genere da 0,0 (peggiore) a 1,0 (migliore), ma dipende dall'implementazione
- Scopo: un unico numero che riassume le prestazioni complessive
- Utilizzo: confronta i modelli, monitora i miglioramenti durante l'allenamento

### Metriche individuali:

- Tipo di metrica: metriche informative per l'analisi
- Tipo di ricompensa: metriche utilizzate durante la formazione RFT
- Interpretazione: valori più alti in genere indicano prestazioni migliori (a meno che non si progettino metriche inverse)

## Benchmark delle prestazioni

Ciò che costituisce una «buona» prestazione dipende dal caso d'uso:

| Intervallo di punteggio | Interpretazione | Azione                                        |
|-------------------------|-----------------|-----------------------------------------------|
| 0,8 - 1,0               | Eccellente      | Modello pronto per l'implementazione          |
| 0,6 - 0,8               | Buona           | Potrebbero essere utili piccoli miglioramenti |
| 0,4 - 0,6               | Giusto          | È necessario un miglioramento significativo   |

| Intervallo di punteggio | Interpretazione | Azione                                                   |
|-------------------------|-----------------|----------------------------------------------------------|
| 0,0 - 0,4               | Scarso          | Rivedi i dati di allenamento e la funzione di ricompensa |

#### Important

Queste sono linee guida generali. Definite le vostre soglie in base ai requisiti aziendali, alle prestazioni del modello di base, ai vincoli specifici del dominio e all'analisi costi-benefici dell'ulteriore formazione.

## Monitoraggio dei lavori con HyperPod MLflow

Puoi utilizzarlo MLflow per tracciare e monitorare i tuoi lavori di formazione su SageMaker HyperPod. Segui questi passaggi per configurarlo MLflow e collegarlo alle tue ricette di allenamento.

### Crea l' MLflowapp

#### AWS CLI Comando di esempio

```
aws sagemaker-mlflow create-mlflow-app \
 --name <app-name> \
 --artifact-store-uri <s3-bucket-name> \
 --role-arn <role-arn> \
 --region <region-name>
```

#### Output di esempio

```
{
 "Arn": "arn:aws:sagemaker:us-east-1:111122223333:mlflow-app/app-LGZE0Z2UY4NZ"
}
```

### Genera un URL prefirmato

#### Comando di esempio AWS CLI

```
aws sagemaker-mlflow create-presigned-mlflow-app-url \
```

```
--arn <app-arn> \
--region <region-name> \
--output text
```

## Output di esempio


```
https://app-LGZE0Z2UY4NZ.mlflow.sagemaker.us-east-1.app.aws/auth?
authToken=eyJhbGciOiJIUzI1NiJ9.eyJhdXRoVG9rZW5JZCI6IkxETVBPUyIsImZhc0NyZWRLbnRpYWxzIjoiQWdWNGhD
```

## Apri l'URL predefinito e visualizza l'app

### Click

```
https://app-LGZE0Z2UY4NZ.mlflow.sagemaker.us-east-1.app.aws/auth?
authToken=eyJhbGciOiJIUzI1NiJ9.eyJhdXRoVG9rZW5JZCI6IkxETVBPUyIsImZhc0NyZWRLbnRpYWxzIjoiQWdWNGhD
```

### Vista




## Passa alla ricetta nella sezione Esegui della tua SageMaker HyperPod ricetta

### Recipe

```
run
 mlflow_tracking_uri: arn:aws:sagemaker:us-east-1:111122223333:mlflow-app/app-
 LGZE0Z2UY4NZ
```

### Vista



## Formazione iterativa

### Panoramica di

L'allenamento iterativo è il processo di messa a punto ripetutamente di un modello attraverso più cicli di allenamento utilizzando diversi metodi di allenamento (formazione, valutazione, analisi degli errori, aggiustamento dei dati/objectives/hyperparameters), con ogni round a partire dal checkpoint precedente. Questo approccio consente di individuare in modo sistematico le modalità di errore del modello, incorporare esempi curati che affrontano punti deboli specifici e adattarsi ai cambiamenti dei requisiti nel tempo.

Vantaggi rispetto alla formazione con un solo passaggio:

- Miglioramento mirato: affronta i modelli di fallimento specifici scoperti attraverso la valutazione
- Perfezionamento adattivo: rispondi ai cambiamenti di distribuzione o ai requisiti di prodotto in evoluzione
- Mitigazione del rischio: convalida i miglioramenti in modo incrementale anziché impegnarsi in un unico lungo periodo di formazione
- Efficienza dei dati: concentra gli sforzi di raccolta dei dati sulle aree in cui il modello ha prestazioni inferiori
- Formazione curricolare: cicli di formazione multipli con dati di qualità sempre più elevata

## Come funziona

### Ubicazione e accesso al checkpoint

Al termine di ogni processo di formazione, viene generato un file manifesto nella posizione di output specificata dal `output_path` parametro nella configurazione di addestramento.

Per accedere al tuo checkpoint

- Vai a quello specificato `output_path` in S3
- Scarica ed estrai il `output.tar.gz` file
- Apri il `manifest.json` file all'interno
- Individua il `checkpoint_s3_bucket` parametro, che contiene l'URI S3 del tuo modello addestrato

### Esempio di struttura manifest.json

```
{
 "checkpoint_s3_bucket": "s3://customer-escrow-<account-number>-smtj-<unique-
 identifier>/<job-name>/stepID",
 ...
}
```

### Informazioni sui bucket di deposito a garanzia

Poiché i pesi di Amazon Nova sono proprietari, i checkpoint dei modelli addestrati vengono archiviati in bucket escrow S3 all'interno di account AWS gestiti anziché essere copiati nel tuo account. Questi secchi di deposito a garanzia:

- Conservate in modo sicuro i pesi dei vostri modelli personalizzati
- Può essere referenziato da altri AWS servizi (inferenza, valutazione e successivi lavori di formazione)
- Sono accessibili solo al tuo AWS account tramite le autorizzazioni IAM
- Addebita i costi di archiviazione standard di S3 nel tuo account (vedi Considerazioni sui costi)

Puoi utilizzare l'escrow bucket path come percorso di allenamento successivo per continuare l'`model_name_or_path` allenamento iterativo.

## Utilizzo dei checkpoint per la formazione iterativa

Configura il tuo prossimo lavoro di formazione in modo da utilizzare il checkpoint precedente come modello base:

```
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
```

## Quando utilizzare la formazione iterativa

### Casi d'uso ideali

Usa la formazione iterativa quando hai:

- Circuiti di feedback: capacità di raccogliere casi di fallimento reali e affrontarli sistematicamente
- Ambienti dinamici: documentazione in evoluzione o argomenti di supporto che richiedono aggiornamenti APIs periodici del modello
- Valutazione affidabile: benchmark e quadri di valutazione solidi (vedi esempi di seguito) per misurare i miglioramenti con sicurezza
- Capacità operative di machine learning: risorse per gestire più cicli di formazione e controllo delle versioni

### Esempi di solidi framework di valutazione

- Suite di benchmark automatizzate con soglie pass/fail
- Protocolli di valutazione umana con metriche di affidabilità tra valutatori
- Scenari di test red-Team che coprono casi limite e input contraddittori
- Infrastruttura di test A/B per misurare l'impatto sulla produzione

## Schemi comuni

SFT → RFT Pipeline: Un modello iterativo usato di frequente prevede:

- SFT first: insegna al modello come risolvere i problemi attraverso esempi dimostrativi
- RFT second: ottimizza le prestazioni nell'ambito più ampio dei problemi utilizzando segnali di ricompensa

Questa sequenza è essenziale quando i modelli hanno inizialmente prestazioni scadenti: la RFT su modelli con precisione prossima allo zero non migliorerà le prestazioni senza prima stabilire le funzionalità di base per la risoluzione dei problemi tramite SFT.

## Quando non utilizzare la formazione iterativa

Evita la formazione iterativa per:

- Attività stabili e ben definite: dati stazionari con requisiti coerenti che consentono già prestazioni quasi massime
- Problemi di classificazione semplici: attività limitate in cui è sufficiente una formazione in un solo passaggio
- Limiti in termini di risorse: mancanza di funzionalità operative ML dedicate per gestire più cicli di formazione
- Guadagni marginali: quando i costi generali non giustificano miglioramenti minimi delle prestazioni

## Esempio di flusso di lavoro: SFT → RFT

Questo esempio dimostra un modello di addestramento iterativo comune per i modelli di ragionamento.

### Fase 1: formazione iniziale SFT

Configura e avvia il tuo processo di formazione SFT con il tuo set di dati:

```
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
```

Fondamento logico: SFT fornisce dimostrazioni aggiuntive che modellano gli output del modello nel formato e nella voce desiderati, stabilendo funzionalità di base.

Al termine dell'allenamento

- Nota quanto `output_path` configurato nel tuo corso di formazione
- Effettua il download `output.tar.gz` da quella posizione
- Estrai e localizza `manifest.json`
- Copia il `checkpoint_s3_bucket` valore

## Fase 2: formazione RFT sul checkpoint SFT

Crea un nuovo lavoro di formazione RFT utilizzando il checkpoint SFT:

```
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>
```

Fondamento logico: la formazione RFT si basa sulle fondamenta SFT e consente al modello di sviluppare modelli di ragionamento più complessi ottimizzati dalla funzione di ricompensa.

## Fase 3: valutazione e iterazione

Esegui la valutazione sul checkpoint RFT per valutare le prestazioni:

```
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
```

Se le metriche target non sono soddisfatte, continua a iterare con dati o iperparametri modificati.

#### Important

La tecnica di allenamento (LoRa vs. Full Rank) deve rimanere coerente in tutte le iterazioni:

- Se usi SFT con LoRa, devi usare RFT con LoRa
- Se usi SFT con Full Rank, devi usare RFT con Full Rank
- Non è possibile passare da LoRa a Full Rank a metà pipeline

#### Important

Se viene utilizzata una chiave KMS per la crittografia nel bucket di output S3 di proprietà di Amazon, la stessa chiave KMS deve essere utilizzata per tutte le iterazioni future.

## Monitoraggio dei progressi tra le iterazioni

Puoi tenere traccia delle metriche MLflow [configurando MLflow](#) i tuoi lavori.

### Crea un'app MLflow

Utilizzo dell'interfaccia utente di Studio: se crei un lavoro di formazione tramite l'interfaccia utente di Studio, viene creata automaticamente MLflow un'app predefinita e selezionata per impostazione predefinita in Opzioni avanzate.

Utilizzo della CLI: se utilizzi la CLI, devi creare un' MLflow app e passarla come input alla richiesta API del lavoro di formazione.

```
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)
```

## Accedi all'app MLflow

Utilizzo della CLI: crea un URL predefinito per accedere all'interfaccia utente dell' MLflow app:

```
aws sagemaker create-presigned-mlflow-app-url \
 --arn $mlflow_app_arn \
 --region $region \
 --output text
```

Utilizzo dell'interfaccia utente di Studio: l'interfaccia utente di Studio mostra le metriche chiave archiviate MLflow e fornisce un collegamento all'interfaccia utente dell' MLflow app.

## Metriche chiave da monitorare

Monitora queste metriche tra le iterazioni per valutare i miglioramenti e monitorare l'avanzamento del lavoro:

### Per SFT

- Curve di perdita in allenamento
- Numero di campioni consumati e tempo di elaborazione dei campioni
- Precisione delle prestazioni su set di test esauriti
- Conformità del formato (ad esempio, velocità di output JSON valida)
- Perplessità sui dati di valutazione specifici del dominio

### Per RFT

- Punteggi medi di ricompensa rispetto agli allenamenti
- Distribuzione dei premi (percentuale di risposte ad alto rendimento)
- Tendenze di convalida e ricompensa (attenzione all'overfitting)
- Percentuali di successo specifiche delle attività (ad esempio, velocità di esecuzione del codice, precisione dei problemi matematici)

## Ambito generale

- Effettua il benchmark dei delta prestazionali tra le iterazioni
- Punteggi di valutazione umana su campioni rappresentativi
- Metriche di produzione (se implementate in modo iterativo)

## Determinare quando fermarsi

Interrompi l'iterazione quando:

- Livelli prestazionali: la formazione aggiuntiva non migliora più in modo significativo le metriche target
- Il cambio di tecnica aiuta: se una tecnica si stabilizza, prova a cambiarla (ad esempio, SFT → RFT → SFT) per superare i limiti prestazionali
- Metriche target raggiunte: i tuoi criteri di successo sono soddisfatti
- Rilevata regressione: le nuove iterazioni riducono le prestazioni (vedi le procedure di rollback di seguito)

Per le procedure di valutazione dettagliate, consulta la sezione Valutazione.

## Best practice

### Inizia in piccolo e scala gradualmente

Inizia con set di dati minimi e singole epoche di formazione per convalidare il tuo approccio prima di espanderlo. Questo aumenta la fiducia e aiuta a identificare tempestivamente i problemi.

### Stabilisci metriche di successo chiare

Definisci indicatori quantitativi e qualitativi prima di iniziare:

Esempi di metriche di successo per caso d'uso

- Risposta alle domande: precisione esatta della corrispondenza, punteggio F1, valutazioni delle preferenze umane
- Generazione di codice: frequenza di superamento del test unitario, successo della compilazione, tempo di esecuzione

- Attività di ragionamento: precisione dei passaggi, correttezza della risposta finale, punteggi di ricompensa
- Generazione di contenuti: punteggi di coerenza, precisione dei fatti, aderenza allo stile

## Implementa la valutazione automat

Imposta pipeline di valutazione automatizzate per monitorare le prestazioni dopo ogni round, consentendo iterazioni rapide e confronti obiettivi.

## Mantieni un controllo rigoroso delle versioni

Documento per ogni iterazione:

- Versioni e modifiche del set di dati
- Posizioni dei checkpoint dei modelli
- Modifiche agli iperparametri
- Metriche e delta delle prestazioni
- Osservazioni qualitative

Ciò aumenta la conoscenza istituzionale e consente il debug.

## Concentrati sulla qualità dei dati piuttosto che sulla quantità

Analizza i casi di fallimento dei round precedenti e aggiungi esempi mirati e di alta qualità anziché limitarti ad aumentare le dimensioni del set di dati.

## Pianifica il budget di iterazione

Pianifica 3-5 iterazioni come intervallo tipico:

- 1-2 iterazioni: spesso sufficienti per semplici miglioramenti o rifiniture finali
- 3-5 iterazioni: adatto per attività complesse che richiedono più cicli di perfezionamento
- Più di 5 iterazioni: può indicare una diminuzione dei rendimenti o la necessità di approcci diversi

Effettua la regolazione in base al budget di calcolo e ai tassi di miglioramento delle prestazioni.

## Implementa funzionalità di rollback

Se un'iterazione introduce regressioni:

- Identifica la regressione: confronta le metriche di valutazione tra i checkpoint
- Torna al checkpoint precedente: utilizza il percorso S3 del checkpoint precedente come `model_name_or_path`
- Modifica l'approccio all'allenamento: modifica i dati, gli iperparametri o la tecnica prima di riprovare
- Documenta l'errore: registra ciò che ha causato la regressione per evitare che si ripeta

Esempio di 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>"
```

## Considerazioni sui costi

### Archiviazione ai checkpoint

- Ubicazione: ai checkpoint archiviati in secchi di deposito a garanzia vengono addebitati i costi di archiviazione S3 standard addebitati sul tuo account AWS
- Conservazione: i checkpoint vengono conservati a tempo indeterminato, a meno che non vengano eliminati esplicitamente
- Gestione: implementa politiche relative al ciclo di vita per archiviare o eliminare i vecchi checkpoint che non ti servono più

Suggerimenti per l'ottimizzazione dei costi

- Elimina i checkpoint intermedi dopo aver convalidato le iterazioni più recenti
- Archivia i checkpoint su S3 Glacier per conservarli a lungo termine a costi inferiori
- Imposta politiche di conservazione in base alle tue esigenze di conformità e sperimentazione

## Limitazioni

### Coerenza familiare modello

Durante l'addestramento iterativo, è necessario utilizzare lo stesso tipo di modello in tutte le iterazioni.

#### Addestramento iniziale

```
run:
 model_type: amazon.nova-2-lite-v1:0:256k
 model_name_or_path: "nova-lite-2/prod"
```

Le iterazioni successive devono utilizzare lo stesso `model_type`

```
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>"
```

### Coerenza della tecnica di allenamento

La tecnica di allenamento deve rimanere coerente tra le iterazioni:

- I modelli addestrati da LoRa possono essere addestrati solo iterativamente con LoRa
- Full-Rank-trained i modelli possono essere addestrati solo iterativamente con Full-Rank

Come funzionano gli adattatori LoRa nell'addestramento iterativo

- Ogni iterazione di addestramento LoRa produce nuovi pesi degli adattatori
- I nuovi adattatori sostituiscono (non si impilano) con gli adattatori precedenti
- Il modello base rimane bloccato; vengono aggiornati solo gli adattatori

### Matrice di compatibilità tecnica

| Addestramento iniziale | Può iterare con                  |
|------------------------|----------------------------------|
| SFT (Full-Rank)        | SFT (Full-Rank), RFT (Full-Rank) |

| Addestramento iniziale | Può iterare con        |
|------------------------|------------------------|
| SFT (LoRa)             | SFT (LoRa), RFT (LoRa) |
| RFT (Full-Rank)        | RFT (Full-Rank)        |
| RFT (LoRa)             | RFT (LoRa)             |

Verifica della compatibilità prima di iniziare un lavoro

- Controlla la tua ricetta di allenamento precedente per identificare il tipo di modello e la tecnica di allenamento (LoRa vs. Full-Rank)
- Assicurati che la tua nuova ricetta corrisponda sia al tipo di modello che alla tecnica
- Controlla manifest.json per confermare che il percorso del checkpoint sia corretto

## Risoluzione dei problemi

Errore: «Sono state rilevate tecniche di addestramento del modello incompatibili»

Causa: la tecnica di allenamento (LoRa vs. Full-Rank) non corrisponde alla tecnica del checkpoint.

Risoluzione: assicurati che la tua ricetta utilizzi la stessa tecnica di allenamento del modello originale:

- Se il checkpoint è stato addestrato con LoRa, usa LoRa nella tua nuova ricetta
- Se il checkpoint è stato addestrato con Full-Rank, usa Full-Rank nella tua nuova ricetta

Errore: «Il modello base per il lavoro estratto da `model_name_or_path` non corrisponde a `model_type`»

Causa: il tipo di modello specificato in `model_type` non corrisponde al modello effettivo nel checkpoint.

Risoluzione: verifica che:

- Quello `model_type` contenuto nella tua ricetta corrisponde al tipo di modello originale
- Il percorso del checkpoint S3 in `model_name_or_path` entrata è corretto
- Stai utilizzando il percorso del file manifest.json corretto

## Esempio di configurazione corretta

```
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>"
```

## Errore: «Configurazione del modello non trovata»

Causa: il percorso di ingresso S3 non `model_name_or_path` è valido o è inaccessibile.

Risoluzione:

- Verifica che il percorso S3 sia stato copiato correttamente dal file `manifest.json`
- Assicurati che il tuo ruolo IAM disponga delle autorizzazioni per accedere al bucket escrow
- Conferma che il precedente processo di formazione è stato completato con successo
- Verifica la presenza di errori di battitura nel percorso

## Regressione delle prestazioni dopo l'iterazione

Sintomi: le metriche di valutazione diminuiscono dopo una nuova iterazione dell'allenamento.

Risoluzione:

- Rollback: utilizza il checkpoint precedente come modello base
- Analizza: esamina i registri di addestramento e la qualità dei dati per verificare se l'iterazione non è riuscita
- Modifica: modifica gli iperparametri (riduci il tasso di apprendimento), migliora la qualità dei dati o riduci le epoche di formazione
- Riprova: avvia una nuova iterazione con modifiche

## SageMaker Inferenza

I modelli Amazon Nova personalizzati sono ora disponibili in SageMaker inferenza. Con Amazon Nova attivo SageMaker, puoi iniziare a ottenere previsioni o inferenze dai tuoi modelli Amazon Nova personalizzati addestrati. SageMaker offre un'ampia selezione di infrastrutture ML e opzioni di implementazione dei modelli per aiutarti a soddisfare tutte le tue esigenze di inferenza ML. Con



SageMaker l'inferenza, è possibile scalare l'implementazione dei modelli, gestirli in modo più efficace in produzione e ridurre il carico operativo.

SageMaker offre diverse opzioni di inferenza, come endpoint in tempo reale per ottenere inferenze a bassa latenza ed endpoint asincroni per batch di richieste. Sfruttando l'opzione di inferenza appropriata per il tuo caso d'uso, puoi garantire un'implementazione e un'inferenza efficienti del modello. [Per ulteriori informazioni sull'inferenza, consulta Implementare modelli per l'inferenza. SageMaker](#)

#### Important

Nell'inferenza sono supportati solo i modelli personalizzati completi e i modelli uniti con LoRA. SageMaker Per i modelli LoRa e i modelli base non uniti, usa Amazon Bedrock.

## Funzionalità

Le seguenti funzionalità sono disponibili per i modelli Amazon Nova sull' SageMaker inferenza:

### Funzionalità del modello

- Generazione di testo

### Implementazione e scalabilità

- Endpoint in tempo reale con selezione personalizzata delle istanze
- Auto Scaling: regola automaticamente la capacità in base ai modelli di traffico per ottimizzare i costi e l'utilizzo della GPU. Per ulteriori informazioni, consulta [Automately Scale Amazon SageMaker Models](#).
- Supporto API di streaming per la generazione di token in tempo reale

### Monitoraggio e ottimizzazione

- CloudWatch Integrazione con Amazon per il monitoraggio e gli avvisi
- Disponibilità Ottimizzazione della latenza con riconoscimento della zona tramite configurazione VPC

### Strumenti di sviluppo

- AWS CLI supporto: per ulteriori informazioni, consulta [AWS CLI Command Reference](#) for SageMaker
- Integrazione con i notebook tramite supporto SDK

## Modelli e istanze supportati

Quando crei gli endpoint di SageMaker inferenza, puoi impostare due variabili di ambiente per configurare la distribuzione: e. `CONTEXT_LENGTH` `MAX_CONCURRENCY`

- `CONTEXT_LENGTH`— Lunghezza totale massima del token (ingresso+output) per richiesta
- `MAX_CONCURRENCY`— Numero massimo di richieste simultanee che l'endpoint servirà

La tabella seguente elenca i modelli, i tipi di istanza e le configurazioni supportate di Amazon Nova supportati. I valori `MAX_CONCURRENCY` rappresentano la concorrenza massima supportata per ogni impostazione `CONTEXT_LENGTH`:

| Modello              | Tipo di istanza | Configurazioni supportate                                                                                               |
|----------------------|-----------------|-------------------------------------------------------------------------------------------------------------------------|
| Amazon Nova<br>Micro | ml.g5.12xlarge  | LUNGHEZZA DEL CONTESTO:<br>4000, CONCORRENZA MASSIMA:<br>32<br><br>LUNGHEZZA_CONTESTO: 8000,<br>CONCORRENZA MASSIMA: 16 |
|                      | ml.g5.24xlarge  | LUNGHEZZA_CONTESTO: 8000,<br>CONCORRENZA MASSIMA: 32                                                                    |
|                      | ml.g6.12xlarge  | LUNGHEZZA_DEL CONTESTO:<br>4000, CONCORRENZA MASSIMA:<br>32<br><br>LUNGHEZZA_CONTESTO: 8000,<br>CONCORRENZA MASSIMA: 16 |
|                      | ml.g6.24xlarge  | LUNGHEZZA_CONTESTO: 8000,<br>CONCORRENZA MASSIMA: 32                                                                    |

| Modello             | Tipo di istanza | Configurazioni supportate                            |
|---------------------|-----------------|------------------------------------------------------|
|                     | ml.g6.48xlarge  | LUNGHEZZA_CONTESTO: 8000,<br>CONCORRENZA MASSIMA: 32 |
|                     | ml.p5.48xlarge  | LUNGHEZZA_CONTESTO: 8000,<br>CONCORRENZA MASSIMA: 32 |
|                     |                 | LUNGHEZZA_CONTESTO: 16000,<br>CONCORRENZA MASSIMA: 2 |
| Amazon Nova<br>Lite | ml.g6.48xlarge  | LUNGHEZZA_CONTESTO: 24000,<br>CONCORRENZA MASSIMA: 1 |
|                     |                 | LUNGHEZZA_CONTESTO: 4000,<br>CONCORRENZA MASSIMA: 32 |
|                     | ml.p5.48xlarge  | LUNGHEZZA_CONTESTO: 8000,<br>CONCORRENZA MASSIMA: 32 |
| Nova 2 Lite         | ml.p5.48xlarge  | LUNGHEZZA_CONTESTO: 16000,<br>CONCORRENZA MASSIMA: 2 |
|                     |                 | LUNGHEZZA_CONTESTO: 24000,<br>CONCORRENZA MASSIMA: 1 |
|                     | ml.p5.48xlarge  | LUNGHEZZA_CONTESTO: 8000,<br>CONCORRENZA MASSIMA: 32 |
|                     | ml.p5.48xlarge  | LUNGHEZZA_CONTESTO: 16000,<br>CONCORRENZA MASSIMA: 2 |
|                     |                 | LUNGHEZZA_CONTESTO: 24000,<br>CONCORRENZA MASSIMA: 1 |
|                     | ml.p5.48xlarge  | LUNGHEZZA_CONTESTO: 8000,<br>CONCORRENZA MASSIMA: 32 |

**Note**

I valori MAX\_CONCURRENCY mostrati sono limiti superiori per ogni impostazione CONTEXT\_LENGTH. È possibile utilizzare lunghezze di contesto inferiori con la stessa concorrenza, ma il superamento di questi valori impedirà la creazione dell'endpoint.

SageMaker

Ad esempio, su Amazon Nova Micro con un ml.g5.12xlarge:

- CONTEXT\_LENGTH=2000 MAX\_CONCURRENCY=32, → Valido
- CONTEXT\_LENGTH=8000, MAX\_CONCURRENCY=32 → Rifiutato (il limite di concorrenza è 16 alla lunghezza del contesto 8000)
- CONTEXT\_LENGTH=8000, → Valido MAX\_CONCURRENCY=4
- CONTEXT\_LENGTH=8000, MAX\_CONCURRENCY=16 → Valido
- CONTEXT\_LENGTH=10000 → Rifiutato (la lunghezza massima del contesto è 8000 in questa istanza)

## Regioni supportate AWS

La tabella seguente elenca le AWS regioni in cui i modelli Amazon Nova sono disponibili in SageMaker inferenza:

| Nome della regione                              | Codice regione | Disponibilità |
|-------------------------------------------------|----------------|---------------|
| Stati Uniti orientali (Virginia settentrionale) | us-east-1      | Disponibilità |
| Stati Uniti occidentali (Oregon)                | us-west-2      | Disponibilità |

## Immagini dei container supportate

La tabella seguente elenca l'immagine del contenitore URIs per i modelli Amazon Nova sull'Amazon SageMaker inferenza per regione. Sono disponibili due tag di immagine per ogni regione: un tag con versione (v1.0.0) e un tag più recente (SM-Inference-latest). Per le implementazioni di produzione, consigliamo di utilizzare il tag versioned.

| Region    | Immagine del contenitore URIs                                                            |
|-----------|------------------------------------------------------------------------------------------|
| 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 |

## Best practice

Per le migliori pratiche sulla distribuzione e la gestione dei modelli su SageMaker, consulta [Best Practices for SageMaker](#).

## Supporto

Per problemi e supporto con i modelli Amazon Nova sull' SageMaker inferenza, contatta l' AWS assistenza tramite la console o il tuo AWS account manager.

### Argomenti

- [Nozioni di base](#)
- [Documentazione di riferimento delle API](#)
- [Valuta i modelli ospitati su SageMaker Inference](#)
- [Implementazione di modelli Amazon Nova Forge nel rilevamento degli abusi di Amazon SageMaker Inference](#)

## Nozioni di base

Questa guida mostra come distribuire modelli Amazon Nova personalizzati su endpoint SageMaker in tempo reale, configurare i parametri di inferenza e richiamare i modelli per i test.

## Prerequisiti

Di seguito sono riportati i prerequisiti per distribuire i modelli Amazon Nova sull' SageMaker inferenza:

- Crea un account Account AWS : se non ne hai già uno, consulta [Creazione](#) di un account. AWS

- Autorizzazioni IAM richieste: assicurati che il tuo utente o ruolo IAM abbia le seguenti politiche gestite allegate:
  - AmazonSageMakerFullAccess
  - AmazonS3FullAccess
- SDKs/CLI Versioni richieste: le seguenti versioni dell'SDK sono state testate e convalidate con modelli Amazon Nova sull' SageMaker inferenza:
  - SageMaker Python SDK v3.0.0+ () per un approccio API basato sulle risorse  
`sagemaker>=3.0.0`
  - Boto3 versione 1.35.0+ () per chiamate API dirette. `boto3>=1.35.0` Gli esempi di questa guida utilizzano questo approccio.
- Aumento della quota di servizio: richiedi un aumento della quota di SageMaker servizio Amazon per il tipo di istanza ML che intendi utilizzare per il tuo endpoint SageMaker Inference (ad esempio, `ml.p5.48xlarge` for endpoint usage). Per una lista di tipi di istanze supportate, consulta [the section called “Modelli e istanze supportati”](#). Per richiedere un aumento, consulta [Richiedere un aumento della](#) quota. Per informazioni sulle quote delle SageMaker istanze, consulta [SageMaker endpoint](#) e quote.

## Passaggio 1: configurare le credenziali AWS

Configura AWS le tue credenziali utilizzando uno dei seguenti metodi:

Opzione 1: AWS CLI (consigliata)

```
aws configure
```

Inserisci la chiave di AWS accesso, la chiave segreta e la regione predefinita quando richiesto.

Opzione 2: file di AWS credenziali

Crea o modifica `~/.aws/credentials`:

```
[default]
aws_access_key_id = YOUR_ACCESS_KEY
aws_secret_access_key = YOUR_SECRET_KEY
```

Opzione 3: variabili di ambiente

```
export AWS_ACCESS_KEY_ID=your_access_key
export AWS_SECRET_ACCESS_KEY=your_secret_key
```

### Note

Per ulteriori informazioni sulle AWS credenziali, consulta [Configurazione e impostazioni dei file di credenziali](#).

## Inizializza i client AWS

Crea uno script o un notebook Python con il seguente codice per inizializzare l' AWS SDK e verificare le tue credenziali:

```
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.")
```

Se l'autenticazione ha esito positivo, dovresti vedere un output che conferma l'ID del tuo account. AWS

## Fase 2: Creare un ruolo di SageMaker esecuzione

Un ruolo di SageMaker esecuzione è un ruolo IAM che concede SageMaker le autorizzazioni per accedere a AWS risorse per tuo conto, come i bucket Amazon S3 per gli artefatti del modello e per la registrazione. CloudWatch

### Creazione del ruolo di esecuzione

#### Note

La creazione di ruoli IAM richiede `iam:CreateRole` e `iam:AttachRolePolicy` autorizzazioni. Assicurati che il tuo utente o ruolo IAM disponga di queste autorizzazioni prima di procedere.

Il codice seguente crea un ruolo IAM con le autorizzazioni necessarie per la distribuzione di modelli personalizzati Amazon Nova:

```
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}")

```

Utilizzo di un ruolo di esecuzione esistente (facoltativo)

Se disponi già di un ruolo di SageMaker esecuzione, puoi utilizzarlo al suo posto:

```

Replace with your existing role ARN
SAGEMAKER_EXECUTION_ROLE_ARN = "arn:aws:iam::YOUR_ACCOUNT_ID:role/
YOUR_EXISTING_ROLE_NAME"

```

Per trovare SageMaker i ruoli esistenti nel tuo account:

```

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

Il ruolo di esecuzione deve avere rapporti di fiducia `sagemaker.amazonaws.com` e autorizzazioni per accedere ad Amazon S3 SageMaker e alle risorse.

[Per ulteriori informazioni sui ruoli di SageMaker esecuzione, consulta SageMaker Ruoli.](#)

## Fase 3: Configurazione dei parametri del modello

Configura i parametri di distribuzione per il tuo modello Amazon Nova. Queste impostazioni controllano il comportamento del modello, l'allocazione delle risorse e le caratteristiche di inferenza. Per un elenco dei tipi di istanza supportati e dei valori `CONTEXT_LENGTH` e `MAX_CONCURRENCY` supportati per ciascuno, consulta [the section called “Modelli e istanze supportati”](#)

### Parametri obbligatori

- `IMAGE`: l'URI dell'immagine del contenitore Docker per il contenitore di inferenza Amazon Nova. Questo verrà fornito da AWS.
- `CONTEXT_LENGTH`: lunghezza del contesto del modello.
- `MAX_CONCURRENCY`: numero massimo di sequenze per iterazione; imposta il limite del numero di richieste utente individuali (prompt) che possono essere elaborate contemporaneamente all'interno di un singolo batch sulla GPU. Intervallo: numero intero maggiore di 0.

### Parametri di generazione opzionali

- `DEFAULT_TEMPERATURE`: controlla la casualità durante la generazione. Intervallo: da 0,0 a 2,0 (0,0 = deterministico, più alto = più casuale).
- `DEFAULT_TOP_P`: soglia di campionamento del nucleo per la selezione dei token. Intervallo: da 1e-10 a 1,0.
- `DEFAULT_TOP_K`: Limita la selezione dei token ai primi K token più probabili. Intervallo: intero -1 o superiore (-1 = nessun limite).
- `DEFAULT_MAX_NEW_TOKENS`: numero massimo di token da generare in risposta (ovvero numero massimo di token di output). Intervallo: numero intero 1 o superiore.
- `DEFAULT_LOGPROBS`: numero di probabilità di log da restituire per token. Intervallo: numero intero compreso tra 1 e 20.

### Configura la tua implementazione

```
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}")

Model Parameters
CONTEXT_LENGTH = "16000" # Maximum total context length
MAX_CONCURRENCY = "2" # Maximum concurrent sequences

Optional: Default generation parameters (uncomment to use)
DEFAULT_TEMPERATURE = "0.0" # Deterministic output
DEFAULT_TOP_P = "1.0" # Consider all tokens
DEFAULT_TOP_K = "50" # Uncomment to limit to top 50 tokens
DEFAULT_MAX_NEW_TOKENS = "2048" # Uncomment to set max output tokens
DEFAULT_LOGPROBS = "1" # Uncomment to enable log probabilities

Build environment variables for the container
environment = {
 'CONTEXT_LENGTH': CONTEXT_LENGTH,
 'MAX_CONCURRENCY': MAX_CONCURRENCY,
}

Add optional parameters if defined
if 'DEFAULT_TEMPERATURE' in globals():
 environment['DEFAULT_TEMPERATURE'] = DEFAULT_TEMPERATURE
if 'DEFAULT_TOP_P' in globals():
 environment['DEFAULT_TOP_P'] = DEFAULT_TOP_P
if 'DEFAULT_TOP_K' in globals():
 environment['DEFAULT_TOP_K'] = DEFAULT_TOP_K
if 'DEFAULT_MAX_NEW_TOKENS' in globals():
 environment['DEFAULT_MAX_NEW_TOKENS'] = DEFAULT_MAX_NEW_TOKENS
if 'DEFAULT_LOGPROBS' in globals():
 environment['DEFAULT_LOGPROBS'] = DEFAULT_LOGPROBS

print("Environment configuration:")
for key, value in environment.items():
 print(f" {key}: {value}")

```

## Configura i parametri specifici della distribuzione

Ora configura i parametri specifici per la distribuzione del tuo modello Amazon Nova, inclusa la posizione degli artefatti del modello e la selezione del tipo di istanza.

Imposta l'identificatore di distribuzione

```
Deployment identifier - use a descriptive name for your use case
JOB_NAME = "my-nova-deployment"
```

Specificare la posizione degli artefatti del modello

Fornisci l'URI Amazon S3 in cui sono archiviati gli artefatti del modello Amazon Nova addestrati. Questo dovrebbe essere il luogo di output del processo di formazione o messa a punto del modello.

```
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/"
```

Seleziona la variante del modello e il tipo di istanza

```
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}")
```

Convenzioni di denominazione

Il codice genera automaticamente nomi coerenti per le AWS risorse:

- Nome del modello: {JOB\_NAME}-{model}-{instance-type}
- Config dell'endpoint: {MODEL\_NAME}-Config

- Nome dell'endpoint: {MODEL\_NAME}-Endpoint

## Fase 4: Creare la configurazione SageMaker del modello e dell'endpoint

In questa fase, creerai due risorse essenziali: un oggetto SageMaker modello che fa riferimento agli artefatti del modello Amazon Nova e una configurazione dell'endpoint che definisce come verrà distribuito il modello.

**SageMaker Modello:** un oggetto modello che racchiude l'immagine del contenitore di inferenza, la posizione degli artefatti del modello e la configurazione dell'ambiente. Si tratta di una risorsa riutilizzabile che può essere distribuita su più endpoint.

**Configurazione degli endpoint:** definisce le impostazioni dell'infrastruttura per la distribuzione, inclusi il tipo di istanza, il numero di istanze e le varianti del modello. Ciò consente di gestire le impostazioni di distribuzione separatamente dal modello stesso.

### Crea il SageMaker modello

Il codice seguente crea un SageMaker modello che fa riferimento agli artefatti del modello Amazon Nova:

```
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}")
```

### Parametri chiave:

- **ModelName**: identificatore univoco per il tuo modello
- **Image**: URI dell'immagine del contenitore Docker per l'inferenza di Amazon Nova
- **ModelDataSource**: posizione in Amazon S3 degli artefatti del modello
- **Environment**: variabili di ambiente configurate nella fase 3
- **ExecutionRoleArn**: ruolo IAM dalla Fase 2
- **EnableNetworkIsolation**: Impostato su True per una maggiore sicurezza (impedisce al container di effettuare chiamate di rete in uscita)

### Crea la configurazione dell'endpoint

Quindi, crea una configurazione dell'endpoint che definisca la tua infrastruttura di distribuzione:

```
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}")
```

### Parametri chiave:

- **VariantName**: identificatore per questa variante del modello (usa «primario» per le implementazioni a modello singolo)

- **ModelName**: fa riferimento al modello creato sopra
- **InitialInstanceCount**: Numero di istanze da implementare (inizia con 1, scala in seguito se necessario)
- **InstanceType**: tipo di istanza ML selezionato nel passaggio 3

Verifica la creazione delle risorse

Puoi verificare che le tue risorse siano state create correttamente:

```
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")
```

## Fase 5: Implementazione dell'endpoint

Il passaggio successivo consiste nell'implementare il modello Amazon Nova creando un endpoint SageMaker in tempo reale. Questo endpoint ospiterà il tuo modello e fornirà un endpoint HTTPS sicuro per effettuare richieste di inferenza.

La creazione degli endpoint richiede in genere 15-30 minuti per il AWS provisioning dell'infrastruttura, il download degli artefatti del modello e l'inizializzazione del contenitore di inferenza.

Creare l'endpoint

```
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}")
```

## Monitora la creazione degli endpoint

Il codice seguente controlla lo stato dell'endpoint fino al completamento della distribuzione:

```
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
```

Verifica che l'endpoint sia pronto

Una volta che l'endpoint è pronto InService, puoi verificarne la configurazione:

```
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

```

## Risoluzione degli errori di creazione degli endpoint

### Motivi di errore comuni:

- Capacità insufficiente: il tipo di istanza richiesto non è disponibile nella tua regione
  - Soluzione: prova un tipo di istanza diverso o richiedi un aumento della quota
- Autorizzazioni IAM: il ruolo di esecuzione non dispone delle autorizzazioni necessarie
  - Soluzione: verifica che il ruolo abbia accesso agli artefatti del modello Amazon S3 e alle autorizzazioni necessarie SageMaker
- Elementi del modello non trovati: l'URI di Amazon S3 è errato o inaccessibile
  - Soluzione: verifica l'URI di Amazon S3 e controlla le autorizzazioni del bucket, assicurati di trovarti nella regione corretta
- Limiti di risorse: limiti di account superati per endpoint o istanze
  - Soluzione: richiedere un aumento della quota di servizio tramite Service Quotas o Support AWS

 Note

Se è necessario eliminare un endpoint guasto e ricominciare da capo:

```
sagemaker.delete_endpoint(EndpointName=ENDPOINT_NAME)
```

## Passaggio 6: richiamare l'endpoint

Una volta creato l'endpoint InService, puoi inviare richieste di inferenza per generare previsioni dal tuo modello Amazon Nova. SageMaker supporta endpoint sincroni (in tempo reale con modalità streaming/non streaming) ed endpoint asincroni (basati su Amazon S3 per l'elaborazione in batch).

### Configura il runtime client

Crea un client SageMaker Runtime con le impostazioni di timeout appropriate:

```
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)
```

### Crea una funzione di inferenza universale

La seguente funzione gestisce sia le richieste in streaming che quelle non in streaming:

```
def invoke_nova_endpoint(request_body):
 """
 Invoke Nova endpoint with automatic streaming detection.

 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)

try:
 print(f"Invoking endpoint ({'streaming' if is_streaming else 'non-streaming'})...")

 if is_streaming:
 response = runtime_client.invoke_endpoint_with_response_stream(
 EndpointName=ENDPOINT_NAME,
 ContentType='application/json',
 Body=body
)

 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
 response = runtime_client.invoke_endpoint(
 EndpointName=ENDPOINT_NAME,
 ContentType='application/json',
 Accept='application/json',
 Body=body
)

 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)}")
```

### Esempio 1: completamento della chat senza streaming

Usa il formato di chat per le interazioni conversazionali:

```
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)
```

### Esempio di risposta:

```
{
 "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
}
}

```

## Esempio 2: semplice completamento del testo

Usa il formato di completamento per una semplice generazione di testo:

```

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)
```

Esempio di risposta:

```
{
 "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
 }
}
```

Esempio 3: completamento della chat in streaming

```
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)
```

### Esempio di output in streaming:

```

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]

```

#### Esempio 4: completamento della chat multimodale

Usa il formato multimodale per l'immissione di immagini e testo:

```

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)

```

#### Esempio di risposta:

```

{
 "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
}
}
```

## Fase 7: Pulizia delle risorse (opzionale)

Per evitare di incorrere in addebiti inutili, elimina le AWS risorse che hai creato durante questo tutorial. SageMaker Gli endpoint sono soggetti a costi durante il loro funzionamento, anche se non state effettuando attivamente richieste di inferenza.

### Important

L'eliminazione delle risorse è permanente e non può essere annullata. Assicuratevi di non aver più bisogno di queste risorse prima di procedere.

## Eliminare l'endpoint

```
import boto3

Initialize SageMaker client
sagemaker = boto3.client('sagemaker', region_name=REGION)

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

L'eliminazione dell'endpoint è asincrona. È possibile monitorare lo stato di eliminazione:

```
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
```

## Eliminare la configurazione dell'endpoint

Dopo l'eliminazione dell'endpoint, rimuovi la configurazione dell'endpoint:

```
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}")
```

## Eliminare il modello

Rimuovi l'oggetto SageMaker del modello:

```
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}")
```

## Documentazione di riferimento delle API

I modelli Amazon Nova SageMaker utilizzano l'API SageMaker Runtime standard per l'inferenza. Per la documentazione completa sull'API, consulta [Testare un modello distribuito](#).

### Richiamata degli endpoint

I modelli Amazon Nova SageMaker supportano due metodi di invocazione:

- Richiamata sincrona: utilizza l'[InvokeEndpoint](#) API per richieste di inferenza in tempo reale e non in streaming.
- Richiamata in streaming: utilizza l'API per le richieste di inferenza in streaming in tempo reale [InvokeEndpointWithResponseStream](#).

### Formato della richiesta

I modelli Amazon Nova supportano due formati di richiesta:

#### Formato di completamento della chat

Usa questo formato per le interazioni conversazionali:

```
{
 "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
 }
}
```

```
}
}
```

## Formato di completamento del testo

Utilizzate questo formato per una semplice generazione di testo:

```
{
 "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
 }
}
```

## Formato di completamento della chat multimodale

Usa questo formato per inserire immagini e testo:

```
{
 "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
}
```

## Parametri della richiesta

- `messages(array)`: Per il formato di completamento della chat. Matrice di oggetti di messaggio con `role` e `content` campi. Il contenuto può essere una stringa di solo testo o un array per input multimodali.
- `prompt(stringa)`: Per il formato di completamento del testo. Il testo di input da cui generare.
- `max_tokens(intero)`: numero massimo di token da generare nella risposta. Intervallo: 1 o superiore.
- `max_completion_tokens(intero)`: alternativa a `max_tokens` per il completamento della chat. Numero massimo di token di completamento da generare.
- `temperature(float)`: controlla la casualità nella generazione. Intervallo: da 0,0 a 2,0 (0,0 = deterministico, 2,0 = casualità massima).
- `top_p(float)`: soglia di campionamento del nucleo. Intervallo: da 1e-10 a 1,0.
- `top_k(numero intero)`: limita la selezione dei token ai primi K token più probabili. Intervallo: -1 o superiore (-1 = nessun limite).
- `stream(boolean)`: Indica se trasmettere la risposta in streaming. Impostato su `per lo streaming`, `true` `false` per il non streaming.
- `logprobs(booleano/intero)`: per il completamento della chat, usa booleano. Per i completamenti di testo, usa il numero intero per indicare il numero di probabilità di log da restituire. Intervallo: da 1 a 20.
- `top_logprobs(numero intero)`: numero di token per i quali è più probabile che vengano restituite le probabilità di log (solo per il completamento della chat).
- `reasoning_effort(stringa)`: Livello di sforzo di ragionamento. Opzioni: «basso», «alto» (completamenti della chat solo per i modelli personalizzati Nova 2 Lite).
- `allowed_token_ids(array)`: Elenco di token IDs che possono essere generati. Limita l'output ai token specificati.
- `truncate_prompt_tokens(numero intero)`: Tronca il prompt a questo numero di token se supera il limite.
- `stream_options(oggetto)`: opzioni per lo streaming delle risposte. Contiene un valore `include_usage` booleano per includere l'utilizzo del token nelle risposte in streaming.

## Formato della risposta

Il formato della risposta dipende dal metodo di invocazione e dal tipo di richiesta:

### Risposta al completamento della chat (non in streaming)

Per le richieste sincrone di completamento della chat:

```
{
 "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]
}

```

## Risposta di completamento del testo (non in streaming)

Per le richieste sincrone di completamento del testo:

```

{
 "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
 }
}
}
}

```

## Completamento della chat, risposta in streaming

Per le richieste di completamento della chat in streaming, le risposte vengono inviate come Server-Sent Events (SSE):

```

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]

```

## Completamento del testo, risposta in streaming

Per le richieste di completamento di testi in streaming:

```

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]
```

### Spiegazione dei campi di risposta

- **id**: identificatore univoco per il completamento
- **object**: Tipo di oggetto restituito («chat.completion», «text\_completion», «chat.completion.chunk»)

- `created`: timestamp Unix di quando è stato creato il completamento
- `model`: Modello utilizzato per il completamento
- `choices`: Gamma di scelte di completamento
- `usage`: informazioni sull'utilizzo dei token, tra cui richiesta, completamento e token totali
- `logprobs`: Registra le informazioni sulla probabilità dei token (quando richiesto)
- `finish_reason`: Motivo per cui il modello ha smesso di generare («stop», «length», «content\_filter»)
- `delta`: Contenuto incrementale nelle risposte in streaming
- `reasoning`: Contenuto di ragionamento quando viene utilizzato `reasoning_effort`
- `token_ids`: Matrice di token IDs per il testo generato

Per una documentazione completa sull'API, consulta [InvokeEndpoint API reference](#) e [InvokeEndpointWithResponseStream API reference](#).

## Valuta i modelli ospitati su SageMaker Inference

Questa guida spiega come valutare i tuoi modelli Amazon Nova personalizzati distribuiti su endpoint di SageMaker inferenza utilizzando [Inspect AI](#), un framework di valutazione open source.

### Note

[Per una guida pratica, consulta il notebook Quickstart di Inspect AI. SageMaker](#)

## Panoramica di

Puoi valutare i tuoi modelli Amazon Nova personalizzati distribuiti sugli SageMaker endpoint utilizzando benchmark standardizzati della comunità di ricerca sull'intelligenza artificiale. Questo approccio ti consente di:

- Valuta modelli Amazon Nova personalizzati (ottimizzati, distillati o adattati in altro modo) su larga scala
- Esegui valutazioni con inferenza parallela su più istanze di endpoint
- Confronta le prestazioni dei modelli utilizzando benchmark come MMLU, TruthfulQA e HumanEval
- SageMaker Effettua l'integrazione con la tua infrastruttura esistente

## Modelli supportati

Il provider di SageMaker inferenza funziona con:

- Modelli Amazon Nova (Nova Micro, Nova Lite, Nova Lite 2)
- Modelli distribuiti tramite server di inferenza compatibili con VLLM o OpenAI
- Qualsiasi endpoint che supporti il formato API OpenAI Chat Completions

## Prerequisiti

Prima di iniziare, assicurati di disporre dei seguenti elementi:

- E Account AWS con le autorizzazioni per creare e richiamare endpoint SageMaker
- AWS credenziali configurate tramite variabili di ambiente AWS CLI o ruolo IAM
- Python 3.9 o versioni successive

## Autorizzazioni IAM richieste

Il tuo utente o ruolo IAM necessita delle seguenti autorizzazioni:

```
{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Effect": "Allow",
 "Action": [
 "sagemaker:InvokeEndpoint",
 "sagemaker:DescribeEndpoint"
],
 "Resource": "arn:aws:sagemaker:*:*:endpoint/*"
 }
]
}
```

## Fase 1: Implementazione di un endpoint SageMaker

Prima di eseguire le valutazioni, è necessario un endpoint di SageMaker inferenza che esegua il modello.

Per istruzioni sulla creazione di un endpoint di SageMaker inferenza con i modelli Amazon Nova, consulta [the section called “Nozioni di base”](#)

Una volta che l'endpoint è in InService stato, annota il nome dell'endpoint da utilizzare nei comandi di valutazione.

## Fase 2: Installare le dipendenze di valutazione

Crea un ambiente virtuale Python e installa i pacchetti richiesti.

```
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-evals

Install AWS dependencies
uv pip install aioboto3 boto3 botocore openai
```

## Fase 3: Configurare le credenziali AWS

Scegli uno dei seguenti metodi di autenticazione:

Opzione 1: AWS CLI (consigliata)

```
aws configure
```

Inserisci AWS l'ID della chiave di accesso, la chiave di accesso segreta e la regione predefinita quando richiesto.

Opzione 2: variabili di ambiente

```
export AWS_ACCESS_KEY_ID=your_access_key
export AWS_SECRET_ACCESS_KEY=your_secret_key
export AWS_DEFAULT_REGION=us-west-2
```

Opzione 3: ruolo IAM

Se è in esecuzione su Amazon EC2 o SageMaker notebook, il ruolo IAM dell'istanza viene utilizzato automaticamente.

Verifica le credenziali

```
import boto3

sts = boto3.client('sts')
identity = sts.get_caller_identity()
print(f"Account: {identity['Account']}")
print(f>User/Role: {identity['Arn']}")
```

## Fase 4: Installare il provider SageMaker

Il SageMaker provider consente a Inspect AI di comunicare con gli SageMaker endpoint. [Il processo di installazione del provider è semplificato nel notebook quickstart.](#)

## Fase 5: Scarica i benchmark di valutazione

Clona il repository Inspect Evals per accedere ai benchmark standard:

```
git clone https://github.com/UKGovernmentBEIS/inspect_evals.git
```

Questo repository include benchmark come:

- MMLU e MMLU-Pro (conoscenza e ragionamento)
- TruthfulQA (veridicità)
- HumanEval (generazione di codice)
- GSM8K (ragionamento matematico)

## Fase 6: Eseguire le valutazioni

Esegui una valutazione utilizzando il tuo SageMaker endpoint:

```
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
```

## Parametri chiave

| Parametro          | Predefinita | Description                                                                                                         |
|--------------------|-------------|---------------------------------------------------------------------------------------------------------------------|
| --max-connections  | 10          | Numero di richieste parallele all'endpoint. Scala in base al numero di istanze (ad esempio, 10 istanze × 25 = 250). |
| --max-retries      | 3           | Riprova per richieste non riuscite. Usa 50-100 per valutazioni di grandi dimensioni.                                |
| -M region_name     | us-east-1   | AWS regione in cui è distribuito l'endpoint.                                                                        |
| -M read_timeout    | 600         | Timeout della richiesta in secondi.                                                                                 |
| -M connect_timeout | 60          | Timeout della connessione in secondi.                                                                               |

## Consigli di ottimizzazione

Per un endpoint a più istanze:

```
10-instance endpoint example
--max-connections 250 # ~25 connections per instance
--max-retries 100 # Handle transient errors
```

Un'impostazione `--max-connections` troppo alta potrebbe sovraccaricare l'endpoint e causare un rallentamento. Impostarlo su un valore troppo basso comporta un sottoutilizzo della capacità.

## Fase 7: Visualizza i risultati

Avvia il visualizzatore Inspect AI per analizzare i risultati della valutazione:

```
inspect view
```



Il visualizzatore mostra:

- Punteggi e metriche complessivi
- Risultati per campione con risposte del modello
- Analisi degli errori e modelli di guasto

## Gestione degli endpoint

### Aggiornare un endpoint

Per aggiornare un endpoint esistente con un nuovo modello o configurazione:

```
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
)
```

### Eliminare un endpoint

```
sagemaker.delete_endpoint(EndpointName=ENDPOINT_NAME)
```

## Introduzione di benchmark personalizzati

Puoi aggiungere nuovi benchmark a Inspect AI utilizzando il seguente flusso di lavoro:

1. Studia il formato del set di dati e le metriche di valutazione del benchmark
2. Rivedi implementazioni simili in `inspect_evals/`
3. Crea un file di attività che converta i record del set di dati in esempi di Inspect AI
4. Implementa risolutori e punteggi appropriati
5. Esegui la convalida con una piccola esecuzione di test

Esempio di struttura delle attività:

```
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()
)
```

## Risoluzione dei problemi

### Problemi comuni

#### Limitazione o timeout degli endpoint

- Ridurre `--max-connections`
- Aumentare `--max-retries`
- Controlla le CloudWatch metriche degli endpoint per problemi di capacità

#### Errori di autenticazione

- Verifica che AWS le credenziali siano configurate correttamente
- Verifica che le autorizzazioni IAM includano `sagemaker:InvokeEndpoint`

#### Errori del modello

- Verifica che l'endpoint sia in InService stato
- Verifica che il modello supporti il formato API OpenAI Chat Completions

### Risorse correlate

- [Ispeziona la documentazione AI](#)
- [Ispeziona il repository Evals](#)

- [SageMaker Guida per gli sviluppatori](#)
- [Implementa modelli per l'inferenza](#)
- [Configurazione di AWS CLI](#)

## Implementazione di modelli Amazon Nova Forge nel rilevamento degli abusi di Amazon SageMaker Inference

AWS si impegna a utilizzare l'IA in modo responsabile. [Per aiutare a prevenire potenziali abusi, quando distribuisce modelli Amazon Nova Forge in Amazon SageMaker Inference, SageMaker Inference implementa meccanismi automatici di rilevamento degli abusi per identificare potenziali violazioni della Politica di utilizzo accettabile \(AUP\) e dei Termini AWS di servizio di Amazon, inclusa la Politica sull'IA responsabile.](#)

I nostri meccanismi di rilevamento degli abusi sono completamente automatizzati, quindi non è prevista alcuna revisione umana o accesso agli input degli utenti o agli output dei modelli.

Il rilevamento automatico degli abusi include:

- Categorizza i contenuti: utilizziamo classificatori per rilevare contenuti dannosi (come contenuti che incitano alla violenza) negli input degli utenti e negli output dei modelli. Un classificatore è un algoritmo che elabora gli input e gli output del modello e che assegna il tipo di danno e il livello di confidenza. Possiamo eseguire questi classificatori sull'utilizzo del modello Amazon Nova Forge. Il processo di classificazione è automatizzato e non prevede la revisione umana degli input degli utenti o degli output del modello.
- Identifica i modelli: utilizziamo le metriche dei classificatori per identificare potenziali violazioni e comportamenti ricorrenti. Possiamo compilare e condividere metriche di classificazione anonime. Amazon SageMaker Inference non memorizza l'input dell'utente o l'output del modello.
- Rilevamento e blocco di materiale pedopornografico (CSAM): sei responsabile dei contenuti che tu (e i tuoi utenti finali) carichi su Amazon SageMaker Inference e devi assicurarti che tali contenuti siano privi di immagini illegali. Per contribuire a fermare la diffusione di CSAM, durante la distribuzione di un modello Amazon Nova Forge in Amazon SageMaker Inference, SageMaker Inference può utilizzare meccanismi automatici di rilevamento degli abusi (come la tecnologia di hash matching o i classificatori) per rilevare CSAM apparente. Se Amazon SageMaker Inference rileva un CSAM apparente negli input delle tue immagini, SageMaker Amazon Inference bloccherà la richiesta e riceverai un messaggio di errore automatico. Amazon SageMaker Inference può anche presentare una segnalazione al National Center for Missing and

Exploited Children (NCMEC) o a un'autorità competente. Prendiamo molto sul serio il problema dei materiali pedopornografici e continueremo ad aggiornare i nostri meccanismi di rilevamento, blocco e segnalazione. Le leggi applicabili potrebbero richiedere l'adozione di ulteriori misure, di cui l'utente è responsabile.

Una volta che i nostri meccanismi automatici di rilevamento degli abusi identificano potenziali violazioni, possiamo richiedere informazioni sull'utilizzo di Amazon SageMaker Inference e sulla conformità ai nostri termini di servizio. Nel caso in cui tu non risponda, non voglia o non sia in grado di rispettare questi termini o politiche, puoi AWS sospendere il tuo accesso ad Amazon Inference. SageMaker Inoltre, se i nostri test automatici rilevano che le risposte del modello non sono coerenti con i nostri termini e politiche, potresti ricevere una fattura per il processo di inferenza non riuscito.

Contatta AWS l'assistenza se hai altre domande. Per ulteriori informazioni, consulta [Amazon SageMaker FAQs](#).

## Inferenza di Amazon Bedrock

Dopo aver addestrato e testato il tuo modello Amazon Nova, puoi distribuirlo su Amazon Bedrock per l'inferenza su scala di produzione. Il processo di distribuzione prevede la creazione di un modello Amazon Bedrock con l' `CreateCustomModel` API, l'esportazione degli artefatti del modello da un bucket Amazon S3 gestito e, una volta che il modello è ATTIVO, la configurazione di un endpoint con inferenza di throughput su richiesta o fornita.

Dopo aver creato un modello personalizzato in SageMaker, puoi utilizzare l' `CreateCustomModel` API per distribuirlo su Amazon Bedrock dall' SageMaker escrow all'esecuzione dell'inferenza. Puoi quindi utilizzarlo `CreateCustomModelDeployment` per creare un endpoint di inferenza OD o impostare un'inferenza di throughput assegnata per un modello PEFT (Parameter Efficient Fine Tuned). È possibile impostare l'inferenza del throughput assegnato per un modello personalizzato Full Rank.

Puoi anche utilizzare l'SDK Amazon Nova Forge per distribuire modelli Amazon Nova personalizzati. L'SDK Amazon Nova Forge offre un'esperienza semplificata per estrarre le informazioni pertinenti da un processo di formazione o da un checkpoint del modello S3 e pubblicarle su Amazon Bedrock. Per ulteriori informazioni, consulta [Amazon Nova Forge SDK](#).

Per i passaggi dettagliati per configurare l'inferenza di Amazon Bedrock per un modello personalizzato, consulta [Distribuzione di modelli Amazon Nova personalizzati su Amazon Bedrock](#).

La sezione seguente fornisce maggiori dettagli sull'inferenza on demand su modelli personalizzati.

## Implementare un modello personalizzato per l'inferenza on demand

Dopo aver creato con successo un modello personalizzato con un processo di personalizzazione del modello (fine-tuning, distillazione o pre-addestramento continuativo), è possibile impostare l'inferenza on demand per il modello.

Per configurare l'inferenza on demand per un modello personalizzato, è necessario implementare il modello con un'implementazione di modelli personalizzati. Dopo aver implementato il modello personalizzato, usa il nome della risorsa Amazon (ARN) dell'implementazione come parametro `modelId` nelle operazioni API `InvokeModel` o `Converse`. Puoi usare il modello implementato per l'inferenza on demand con le funzionalità di Amazon Bedrock quali playground, agenti e basi di conoscenza.

### Argomenti

- [Modelli supportati](#)
- [Implementazione di un modello personalizzato](#)
- [Utilizzo di un'implementazione per l'inferenza on demand](#)
- [Eliminare l'implementazione di un modello personalizzato](#)

### Modelli supportati

Puoi configurare l'inferenza on demand per i seguenti modelli:

- Amazon Nova Canvas
- Amazon Nova Lite
- Amazon Nova Micro
- Amazon Nova Pro

### Implementazione di un modello personalizzato

Puoi implementare un modello personalizzato con la console Amazon Bedrock oppure AWS Command Line Interface. AWS SDKs Per informazioni sull'uso dell'implementazione per l'inferenza, consulta [Use a deployment for on-demand inference](#).

### Argomenti

- [Implementare un modello personalizzato \(console\)](#)

- [Implementazione di un modello personalizzato \(AWS Command Line Interface\)](#)
- [Implementazione di un modello personalizzato \(AWS SDKs\)](#)

## Implementare un modello personalizzato (console)

Puoi implementare un modello personalizzato dalla pagina Modelli personalizzati come segue. Puoi anche implementare un modello dalla pagina Modello personalizzato on demand con gli stessi campi. Per trovare questa pagina, in Inferenza e valutazione nel pannello di navigazione, seleziona Modello personalizzato on demand.

### Per l'implementazione di un modello personalizzato

1. Accedi all' Console di gestione AWS utilizzo di un [ruolo IAM con autorizzazioni Amazon Bedrock](#) e apri la console Amazon Bedrock all'indirizzo. <https://console.aws.amazon.com/nova/>
2. Dal riquadro di navigazione a sinistra, scegli Modelli personalizzati in Modelli di fondazione.
3. Nella scheda Modelli, seleziona il pulsante di opzione relativo al modello che vuoi implementare.
4. Seleziona Imposta inferenza e scegli Implementa per on demand.
5. In Dettagli implementazione, fornisci le seguenti informazioni:
  - Nome implementazione (obbligatorio): immetti un nome univoco per l'implementazione.
  - Descrizione (facoltativo): inserisci una descrizione per la tua implementazione.
  - Tag (facoltativo): aggiungi tag per l'allocazione dei costi e la gestione delle risorse.
6. Scegli Create (Crea). Quando lo stato è Completed, il modello personalizzato è pronto per l'inferenza on demand. Per ulteriori informazioni sull'uso del modello personalizzato, consulta [Use a deployment for on-demand inference](#).

## Implementazione di un modello personalizzato (AWS Command Line Interface)

Per distribuire un modello personalizzato per l'inferenza su richiesta utilizzando il AWS Command Line Interface, usa il `create-custom-model-deployment` comando con Amazon Resource Name (ARN) del tuo modello personalizzato. Questo comando utilizza l'operazione API.

[CreateCustomModelDeployment](#) Restituisce l'ARN dell'implementazione che è possibile usare come `modelId` quando si effettuano richieste di inferenza. Per informazioni sull'uso dell'implementazione per l'inferenza, consulta [Use a deployment for on-demand inference](#).

```
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
```

## Implementazione di un modello personalizzato (AWS SDKs)

Per implementare un modello personalizzato per l'inferenza su richiesta, utilizza l'operazione [CreateCustomModelDeployment](#) API con Amazon Resource Name (ARN) del tuo modello personalizzato. La risposta restituisce l'ARN dell'implementazione che è possibile usare come `modelId` quando si effettuano richieste di inferenza. Per informazioni sull'uso dell'implementazione per l'inferenza, consulta [Use a deployment for on-demand inference](#).

Il seguente codice mostra come usare SDK per Python (Boto3) per implementare un modello personalizzato.

```
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
```

## Utilizzo di un'implementazione per l'inferenza on demand

Dopo aver implementato il modello personalizzato per l'inferenza on demand, puoi usarlo per generare risposte effettuando richieste di inferenza. Per le operazioni `InvokeModel` o `Converse` usa il nome della risorsa Amazon (ARN) di implementazione Amazon come `modelId`.

Per ulteriori informazioni sull'esecuzione di richieste di inferenza, consulta i seguenti argomenti:

- [Invia prompt e genera risposte con l'inferenza del modello](#)
- [Prerequisiti per l'esecuzione dell'inferenza del modello](#)
- [Invia richieste e genera risposte usando l'API](#)

## Eliminare l'implementazione di un modello personalizzato

Dopo aver terminato di usare il modello per l'inferenza on demand, puoi eliminare l'implementazione. Dopo aver eliminato l'implementazione, non puoi usarla per l'inferenza on demand, ma il modello personalizzato sottostante non viene eliminato.

Puoi eliminare una distribuzione di modelli personalizzati con la console Amazon Bedrock AWS Command Line Interface, oppure AWS SDKs.



### Important

L'eliminazione di un'implementazione di un modello personalizzato è irreversibile. Assicuratevi di non avere più bisogno dell'implementazione prima di procedere con l'eliminazione. Se devi utilizzare nuovamente il modello personalizzato per l'inferenza on demand, dovrai creare una nuova implementazione.

## Argomenti

- [Eliminazione dell'implementazione di un modello personalizzato \(console\)](#)
- [Eliminare l'implementazione di un modello personalizzato \(AWS Command Line Interface\)](#)
- [Eliminazione dell'implementazione di un modello personalizzato \(AWS SDKs\)](#)

## Eliminazione dell'implementazione di un modello personalizzato (console)

Per eliminare l'implementazione di un modello personalizzato

1. Nel riquadro di navigazione, in Inferenza e valutazione, seleziona Modello personalizzato on demand.
2. Scegli l'implementazione del modello personalizzato da eliminare.
3. Scegli Elimina.
4. Nella finestra di dialogo di conferma inserisci il nome dell'implementazione per confermare l'eliminazione.
5. Seleziona Elimina per confermare.

Lo stato dell'implementazione diventerà `Deleting` mentre l'eliminazione è in corso. Una volta completata, l'implementazione verrà rimossa dall'elenco.

## Eliminare l'implementazione di un modello personalizzato (AWS Command Line Interface)

Per eliminare una distribuzione di un modello personalizzato utilizzando il AWS Command Line Interface, utilizza il `delete-custom-model-deployment` comando con il tuo identificatore di distribuzione.

```
aws bedrock delete-custom-model-deployment \
```

```
--custom-model-deployment-identifier "deployment-arn-or-name" \
--region region
```

## Eliminazione dell'implementazione di un modello personalizzato (AWS SDKs)

Per eliminare un modello di distribuzione personalizzato a livello di codice, utilizza l'operazione [DeleteCustomModelDeployment](#) API con l'Amazon Resource Name (ARN) o il nome della distribuzione. Il seguente codice mostra come utilizzare l'SDK per Python (Boto3) per eliminare l'implementazione di un modello personalizzato.

```
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
```

## Inferenza on demand su modelli personalizzati

L'inferenza su richiesta (on-demand, OD) ti consente di eseguire inferenze sui tuoi modelli Amazon Nova personalizzati senza mantenere gli endpoint di throughput forniti. Questo ti aiuta a ottimizzare i costi e a scalare in modo efficiente. Con l'inferenza on demand, i costi vengono addebitati in base all'utilizzo, misurato in token, sia in entrata che in uscita.

## Requisiti di compatibilità

Si applicano i seguenti requisiti di compatibilità:

- L'inferenza OD è supportata per i modelli di comprensione personalizzati di Amazon Nova Pro, Lite e Micro. L'inferenza OD non è supportata per i modelli di generazione di contenuti personalizzati di Nova.
- L'inferenza OD è supportata per i modelli di comprensione personalizzati di Amazon Nova addestrati dopo il 16 luglio 2025. I modelli personalizzati addestrati prima del 16 luglio 2025 non sono compatibili con l'inferenza OD.
- Personalizzazione di Amazon Bedrock: l'inferenza OD è supportata per i modelli personalizzati con la personalizzazione di Amazon Bedrock e per i modelli studente che sono stati distillati da un modello insegnante con Amazon Bedrock.
- SageMaker Personalizzazione AI: per i modelli personalizzati nell' SageMaker intelligenza artificiale, l'inferenza OD è supportata solo per i modelli PEFT (Parameter-Efficient Fine-Tuned) quando il modello è ospitato su Amazon Bedrock. Ciò include l'ottimizzazione diretta delle preferenze più PEFT. L'inferenza OD non è supportata per i modelli con fine-tuning completo.

## Addestramento dei modelli e inferenza

Quando addestra un nuovo modello Amazon Nova Pro, Lite o Micro personalizzato su Amazon Bedrock o SageMaker AI utilizzando PEFT dopo il 16 luglio 2025, il modello sarà automaticamente compatibile con le opzioni di inferenza fornite e su richiesta. Puoi selezionare il metodo di inferenza preferito quando implementi il modello.

Per utilizzare l'inferenza OD con un modello addestrato dopo il 16 luglio 2025, completa i seguenti passaggi:

1. [Crea un nuovo lavoro di ottimizzazione con l'API di personalizzazione Amazon Bedrock o l'API di personalizzazione AI. SageMaker](#)
2. [Implementa il modello appena addestrato su Amazon Bedrock utilizzando l>CreateCustomModel API.](#)
3. Implementa per l'inferenza su richiesta utilizzando l'API. CustomModelDeployment

## Limiti di frequenza

I seguenti limiti di richieste al minuto (RPM) e token al minuto (TPM) si applicano alle richieste di inferenza on demand:

| Modello base per modello personalizzato | RPM per implementazione del modello personalizzato | TPM per implementazione di modelli personalizzati |
|-----------------------------------------|----------------------------------------------------|---------------------------------------------------|
| Nova 2 Lite                             | 2.000                                              | 4.000.000                                         |

Per saperne di più sulle quote disponibili per Amazon Nova, consulta [Quote per Amazon Nova](#).

## Latenza

Puoi aspettarti una differenza di end-to-end latenza (ovvero Time To First Token (TTFT)) del 20-55% tra l'invocazione del modello base e l'adattatore. Il valore esatto di latenza varia in base alle dimensioni del modello ed è in linea con gli standard del settore.

## Limitazioni della personalizzazione dei modelli Amazon Nova

La personalizzazione di Amazon Nova non supporta le seguenti funzionalità su SageMaker.

- Accesso tramite SSH all'istanza per trovare le metriche

Per via dei controlli di sicurezza in atto, non è possibile accedere tramite SSH al nodo principale dell'istanza di addestramento algo-1 per trovare statistiche di memoria o statistiche NVIDIA e convalidare le fasi di addestramento.

- Support per SageMaker trainer SDK

SageMaker al momento il trainer non è disponibile per avviare lavori di formazione. Attualmente puoi avviare i job di addestramento solo tramite l'API dello strumento di stima.

- Le piscine calde non sono accessibili ai SageMaker corsi di formazione

A causa dei controlli di sicurezza in atto, le piscine SageMaker calde non possono essere utilizzate per mantenere l'istanza nella piscina calda fino al momento in cui vivrà.

- Unione di modelli personalizzati

L'unione di più modelli non è attualmente supportata. Ciò significa che non è possibile creare più adattatori LoRA ed eseguire un'operazione di unione di più modelli con il modello di base.

- Strumento di osservabilità supportato

[TensorBoard](#) è l'unico strumento di osservabilità supportato per visualizzare le metriche relative ai lavori di SageMaker formazione. [MLFlow](#) [WandB](#) non sono attualmente supportati. [Per ulteriori informazioni sull'utilizzo di TensorBoard in SageMaker, vedere TensorBoard in SageMaker](#)

# Amazon Nova Forge

Amazon Nova Forge è un first-of-its-kind servizio che offre alle organizzazioni il modo più semplice ed economico per creare i propri modelli di frontiera utilizzando Nova.

Amazon Nova Forge introduce il concetto di modelli di «formazione aperta», che offrono alle organizzazioni l'accesso a una serie di checkpoint iniziali dei modelli e la possibilità di combinare dati proprietari con set di dati curati da Amazon in ogni fase della formazione del modello. Ciò consente ai modelli di massimizzare l'apprendimento da dati proprietari riducendo al minimo il rischio di dimenticare abilità fondamentali come il ragionamento.

Nova Forge offre le seguenti funzionalità chiave:

- Accedi ai checkpoint in tutte le fasi dello sviluppo del modello e sfrutta i nuovi modelli Nova prima che siano ampiamente disponibili
- Combina i tuoi dati proprietari con i dati di formazione curati da Amazon Nova
- Esegui l'apprendimento per rinforzo con funzioni di ricompensa nel tuo ambiente
- Utilizza ricette a pulsanti ottimizzate per la creazione con Nova tramite flussi di lavoro visivi o un'interfaccia a riga di comando
- Utilizza il Responsible AI Toolkit per allineare i modelli alle linee guida sull'intelligenza artificiale responsabile di Amazon Nova durante il processo di formazione e implementare controlli di runtime per moderare le risposte del modello durante l'inferenza.

## Prerequisiti

Argomenti

- [Iscriviti a Nova Forge](#)
- [Altri prerequisiti](#)

## Iscriviti a Nova Forge

Per richiedere l'accesso al servizio Amazon Nova Forge, aggiungi il seguente tag al ruolo IAM della tua console: `key forge-subscription with value true`. Dopo aver aggiunto questo tag al tuo ruolo, vai su SageMaker AI Console > Formazione e personalizzazione dei modelli e fai clic su Nova Forge.

In questa pagina troverai i dettagli sul servizio, le informazioni sui prezzi e le funzionalità. Puoi richiedere l'abbonamento e quindi gestirlo da questa pagina.

1. Il ruolo dovrebbe avere il permesso di chiamare api `ListAttachedRolePolicy` e la risposta dovrebbe includere una delle due `AdministratorAccess` `AmazonSageMakerFullAccess` politiche.
2. Il ruolo di accesso dovrebbe avere l'autorizzazione a chiamare api e `ListRoleTags` i tag di risposta dovrebbero includere `tag.key=forged-subscription`.

## Altri prerequisiti

Assicurati inoltre che siano soddisfatti i seguenti prerequisiti:

1. [Prerequisiti generali](#)
2. [Passaggi aggiuntivi per gli utenti: aggiungi Restricted Instance Group \(RIG\) al tuo SageMaker HyperPod cluster \(per completare i passaggi seguenti\)](#)

## Accesso e configurazione di Nova Forge

Per entrare a far parte di Nova Forge, segui questa procedura in due fasi:

- Fase 1: Abbonarsi a Nova Forge
- Fase 2: HyperPod Configurazione dell'infrastruttura

## Ottenere i documenti di Nova Forge

Per ottenere i documenti di Nova Forge, procedi nel seguente modo:

```
mkdir NovaForgeHyperpodCLI
cd NovaForgeHyperpodCLI
aws s3 cp s3://nova-forge-c7363-206080352451-us-east-1/v1/ ./ --recursive
pip install -e .
```

## Fase 1: Abbonarsi a Nova Forge

### Riepilogo rapido:

1. Verifica di disporre dell'accesso come amministratore all'account Amazon Web Services.
2. Vai alla console SageMaker AI e richiedi l'accesso a Nova Forge.
3. Attendi che il team Nova invii un'e-mail di conferma dopo l'approvazione della richiesta di abbonamento.
4. Etichetta il tuo ruolo di esecuzione con il `forge-subscription` tag. Questo tag è necessario per accedere alle funzionalità e ai checkpoint di Nova Forge. Aggiungi il seguente tag al tuo ruolo di esecuzione:
  - Chiave: `forge-subscription`
  - Valore: `true`

### Guida dettagliata

Per abbonarsi a Nova Forge e utilizzare efficacemente il servizio di personalizzazione, un cliente Amazon Web Services deve disporre dell'accesso come amministratore al proprio account Amazon Web Services o chiedere all'amministratore di concedere l'accesso come amministratore. Questo documento descrive i passaggi necessari per:

- Accesso sicuro per gli amministratori
- Configura le politiche per l'iscrizione a Nova Forge
- Accedi alle ricette di personalizzazione
- Configura la personalizzazione
- Monitora il flusso di lavoro
- Valuta il checkpoint del modello personalizzato

### Opzione A

Flusso 1: l'utente dell'account deve contattare l'amministratore dell'account per richiedere quanto segue:

- Aggiungi il `forge-subscription` tag all'account tramite IAM (consulta l'Appendice A per i passaggi).



- Aggiungi le `ListAttachedRolePolicies` autorizzazioni `ListRoleTags` e tramite IAM (consulta l'Appendice B per i passaggi).

**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

## Opzione B

Flusso: l'utente dell'account deve contattare l'amministratore dell'account per richiedere l'accesso da amministratore all'account.


- Una volta concesso l'accesso da amministratore, segui la procedura descritta in Flow 2.

## Flusso 2. Account Amazon Web Services con accesso da amministratore


- Aggiungi il tag `forge-subscription` all'account tramite IAM. Vedi i passaggi nell'Appendice A

## Appendice A. Aggiungere una politica di falsificazione dell'abbonamento all'account Amazon Web Services

1. Vai alla dashboard IAM di Amazon Web Services. Fai clic su Ruoli a sinistra. Cerca admin e fai clic sul ruolo di amministratore



2. Seleziona < AssumedRoleToUse > (ad es. libsAdminAccess). Fate clic sulla scheda Tag.



3. Fai clic su Gestisci schede. Aggiungi un nuovo tag. Digita «forge-subscription» in Key e fai clic su Salva modifiche

Amazon Q IAM > Roles > libsAdminAccess-DO-NOT-DELETE > Tags for libsAdminAccess-DO-NOT-DELETE

### Tags for libsAdminAccess-DO-NOT-DELETE [Info](#)

**Tags (2)**  
Tags are key-value pairs that you can add to AWS resources to help identify, organize, or search for resources.

| Key                | Value - optional   |                        |
|--------------------|--------------------|------------------------|
| forge-subscription | forge-subscription | <a href="#">Remove</a> |
| prime-subscription | prime-subscription | <a href="#">Remove</a> |

[Add new tag](#)  
You can add up to 48 more tags.

[Cancel](#) [Save changes](#)

4. Assicurati di vedere forge-subscription come chiave nella sezione Tag

Amazon Q IAM > Roles > libsAdminAccess-DO-NOT-DELETE

### Identity and Access Management (IAM) [Search IAM](#)

- Dashboard
- ▼ Access management
  - User groups
  - Users
  - Roles**
  - Policies
  - Identity providers
  - Account settings
  - Root access management
  - Temporary delegation requests
- ▼ Access reports
  - Access Analyzer
  - Resource analysis

**Tags updated.**

### libsAdminAccess-DO-NOT-DELETE [Info](#)

**Summary**

**Creation date**  
November 06, 2025, 09:29 (UTC-08:00)

**ARN**  
[arn:aws:iam::f...s-DO-NOT-DE](#)

**Last activity**  
[9 minutes ago](#)

**Maximum session**  
1 hour

**Permissions** | **Trust relationships** | **Tags (2)** | **Last Access**


### Tags (2) [Info](#)

Tags are key-value pairs that you can add to AWS resources to help identify


| Key                |
|--------------------|
| forge-subscription |

## Appendice B. Aggiungere ListAttachedPolicies politiche ListRoleTags all'account Amazon Web Services per il ruolo non amministratore da parte dell'amministratore

1. Vai alla dashboard IAM di Amazon Web Services. Fai clic su Ruoli a sinistra. Cerca < AssumedRoleToUse > (ad es. ForgeAccessRole) e fai clic sul ruolo < AssumedRoleToUse > (es. ForgeAccessRole)




2. Fate clic sul ruolo < AssumedRoleToUse > (ad es. ForgeAccessRole) e selezionate Tag. Aggiungi un nuovo tag con il tipo «forge-subscription»



3. In Autorizzazioni, aggiungi una nuova autorizzazione: Aggiungi autorizzazioni → Crea politica in linea → Aggiungi la seguente politica elencata di seguito

```
{
 "Version": "2012-10-17",
 "Statement": [
 {
 "Sid": "VisualEditor0",
 "Effect": "Allow",
 "Action": [
 "iam:ListRoleTags",
 "iam:ListAttachedRolePolicies"
],
 "Resource": "*"
 }
]
}
```



## Passaggio 2. Configura l'infrastruttura HyperPod

Configura l'infrastruttura necessaria seguendo [le istruzioni del workshop](#) per configurare l'ambiente con funzionalità abilitate a Forge.

## Impostazioni di moderazione dei contenuti

Se hai bisogno di accedere a Nova Forge, sono disponibili impostazioni di moderazione dei contenuti personalizzabili (CCMS) per i modelli Amazon Nova Lite 1.0 e Pro 1.0. CCMS consente di regolare i controlli di moderazione dei contenuti per allinearli a requisiti aziendali specifici, mantenendo al contempo le protezioni essenziali e responsabili dell'IA. Per determinare se un modello di business è appropriato per CCMS, contatta un Account Manager. AWS

Per ulteriori informazioni sulla configurazione e l'utilizzo di CCMS con modelli personalizzati, consulta la sezione [Responsible AI Toolkit e moderazione dei contenuti](#).

## Pre-allenamento continuo e a metà allenamento

### Note

La documentazione dettagliata viene fornita una volta sottoscritta

Nova Forge CPT offre funzionalità avanzate oltre al CPT standard, incluso l'accesso a checkpoint intermedi e la miscelazione dei dati con il corpus di pre-formazione di Nova. Queste funzionalità consentono un adattamento più efficiente del dominio e una migliore conservazione delle funzionalità generali del modello.

### Cosa sono i checkpoint intermedi e perché sono necessari?

I checkpoint intermedi sono istantanee del modello Amazon Nova salvate in diverse fasi del pre-addestramento, prima che il modello raggiunga lo stato finale pronto per la produzione. Durante lo sviluppo del modello, Amazon Nova viene sottoposto a diverse fasi di formazione: pre-formazione iniziale con tasso di apprendimento costante, riduzione del tasso di apprendimento, formazione con estensione del contesto e infine formazione sull'allineamento e sulla sicurezza che segue le istruzioni. Per il CPT, i checkpoint intermedi sono spesso preferibili al checkpoint Prod finale perché sono più plastici e ricettivi all'adattamento del dominio. Il checkpoint Prod è stato sottoposto a un'ampia formazione sull'allineamento e sulla sicurezza, che ottimizza il modello per l'uso conversazionale generale ma può renderlo resistente all'apprendimento di nuovi schemi specifici del dominio durante il CPT. Al contrario, i checkpoint contenenti solo testo parzialmente e completamente preaddestrato mantengono le caratteristiche di pre-addestramento del modello. Non sono stati fortemente orientati verso comportamenti specifici, il che li rende punti di partenza più efficienti per l'adattamento al dominio. Quando si esegue un CPT su larga scala (token >10B), partire da checkpoint intermedi in genere si ottiene una convergenza più rapida, una migliore stabilità della formazione e un'acquisizione più efficace delle conoscenze di dominio. Tuttavia, per il CPT su piccola scala (token <10B), o quando è necessario preservare le funzionalità di seguire le istruzioni, il checkpoint Prod può essere più appropriato in quanto consente l'adattamento del dominio mantenendo le capacità di conversazione del modello.

Per il CPT sono necessari più checkpoint intermedi perché offrono diversi livelli di plasticità del modello che influiscono sull'efficienza con cui il modello può assorbire nuove conoscenze di dominio.

L'ultimo checkpoint Prod è stato sottoposto a un'ampia formazione sull'allineamento e sulla sicurezza, che lo ottimizza per l'uso conversazionale generale ma lo rende resistente all'apprendimento di nuovi schemi specifici del dominio. In altre parole, è stato rafforzato dopo l'allenamento. Al contrario, i checkpoint precedenti mantengono le caratteristiche di pre-allenamento del modello e non sono stati fortemente orientati verso comportamenti specifici, il che li rende più plastici e ricettivi all'adattamento del dominio.

Per ottenere la migliore efficienza della formazione, sono disponibili più punti di controllo intermedi.

## Quali posti di blocco sono disponibili?

### Nova 2.0

Esistono tre checkpoint Amazon Nova Lite 2.0.

- **PRE-TRAINED** - [nova-lite-2/pretraining-text-RD]: Questo è il checkpoint dopo il ritmo di apprendimento costante e le fasi di accelerazione della formazione preliminare di Amazon Nova, in cui il modello viene addestrato su trilioni di token.
- **MID-TRAINED** - [nova-lite-2/pretraining-text-CE]: Questo checkpoint consente di introdurre volumi intermedi di dati non strutturati con un tasso di apprendimento più conservativo rispetto alla formazione preliminare, assorbendo le conoscenze specifiche del dominio ed evitando al contempo catastrofici dimenticamenti.
- **POST-TRAINED** - [nova-lite-2/prod]: Questo è il checkpoint finale completamente allineato del modello che ha superato tutte le fasi pertinenti e successive alla formazione.

La tabella seguente illustra le diverse condizioni prima e durante l'allenamento.

| Tipo di dati                                                                                                    | Esegui                          | Con Checkpoint |
|-----------------------------------------------------------------------------------------------------------------|---------------------------------|----------------|
| Dati di dominio grezzi non strutturati su larga scala<br>(documenti, registri, articoli, codice, ecc.)          | Formazione preliminare continua | Pre-addestrato |
| Dati di dominio non strutturati non strutturati su larga scala<br>(documenti, registri, articoli, codice, ecc.) | A metà allenamento              | Pre-addestrato |



| Tipo di dati                                                                                                                 | Esegui                                       | Con Checkpoint     |
|------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------|--------------------|
| Volumi più piccoli di dati grezzi non strutturati. Tracce di ragionamento strutturato/dati CoT                               | A metà allenamento                           | A metà allenamento |
| Dimostrazioni strutturate (coppie input-output di alta qualità, istruzioni dettagliate sulle attività, dialoghi a più turni) | Ottimizzazione completa                      | Metà allenato      |
| Dimostrazioni strutturate (coppie input-output di alta qualità, istruzioni dettagliate sulle attività, dialoghi a più turni) | Regolazione precisa efficiente dei parametri | Post-addestramento |

## Quale checkpoint usare?

I checkpoint con solo testo parzialmente preaddestrato e solo testo completamente preaddestrato in genere convergono più rapidamente e richiedono meno passaggi di formazione per l'adattamento del dominio. Tuttavia, non sono in grado di adattare le istruzioni e dovrebbero sottoporsi a fasi successive all'addestramento per poter svolgere attività utili e seguire le istruzioni. Il punto di controllo GA potrebbe richiedere più passaggi per adattarsi, ma offre un punto di partenza più sicuro per esperimenti su piccola scala e manterrà alcune delle sue capacità post-addestramento anche dopo l'addestramento CPT.

In generale, con set di dati di addestramento di grandi dimensioni (più di 10 miliardi di token), iniziate da punti di controllo solo testuali parzialmente preaddestrati o solo testo completamente preaddestrato per un addestramento più efficiente e stabile, poiché la base di conoscenze del modello verrà modificata in modo sostanziale. Con set di dati di piccole dimensioni (<10 miliardi di token), utilizzate il checkpoint GA per preservare le capacità di seguire le istruzioni adattandovi al dominio.

## Come utilizzare il mixaggio dei dati per Nova 2.0?

Quando si esegue il CPT con i dati di un nuovo dominio, è estremamente utile combinare i nuovi dati con alcuni dei dati utilizzati in precedenza nella fase di pre-addestramento del modello. La combinazione di dati vecchi con dati di nuovo dominio risolve due problemi:

- **Dimenticare il controllo:** previene l'oblio catastrofico preservando le competenze e le conoscenze esistenti del modello. Senza la miscelazione dei dati, l'addestramento esclusivamente su dati di dominio ristretto fa sì che il modello sovrascriva le funzionalità generali. Ad esempio, un modello addestrato solo su documenti legali potrebbe perdere la capacità di codificare o fare calcoli matematici. La combinazione dei set di dati del dominio generale preserva queste competenze generali durante l'acquisizione del nuovo dominio.
- **Stabilità di ottimizzazione:** mantiene la stabilità dell'allenamento ancorando le rappresentazioni interne del modello. Durante il CPT, le funzionalità apprese dal modello vengono modificate e la miscelazione dei dati fornisce gradienti provenienti da diverse fonti che guidano questo adattamento senza intoppi. Senza di essa, l'addestramento su distribuzioni ristrette può causare instabilità del gradiente, dove le rappresentazioni del modello cambiano troppo drasticamente, con conseguenti divergenze nell'addestramento, picchi di perdita o collasso delle capacità esistenti. Questo è il compromesso tra stabilità e plasticità: il modello deve essere sufficientemente plastico per apprendere nuove conoscenze di settore, ma abbastanza stabile da non rompere ciò che già conosce.

### Funzionalità di mixaggio dei dati Nova CPT

L'accesso ai dati e ai checkpoint di pre-formazione di Amazon Nova è una delle offerte principali della personalizzazione CPT di Amazon Nova. La personalizzazione CPT di Amazon Nova consente di combinare facilmente i dati di dominio con il corpus di pre-formazione di Amazon Nova. Inoltre, è possibile modificare il rapporto di campionamento delle specifiche categorie di dati di Amazon Nova (ad esempio codice, matematica, ragionamento, ecc.) e controllarne le proporzioni per integrare i dati del dominio. Ciò consente di rafforzare le funzionalità in linea con il caso d'uso adattando al contempo il modello al dominio specifico.

### Individuazione del rapporto di miscelazione ottimale

Il rapporto ottimale tra dati di Amazon Nova e dati di dominio dipende dal dominio, dalla complessità, dalle dimensioni, dalla qualità del set di dati e dall'importanza di mantenere le funzionalità generali. Questo rapporto deve essere scoperto attraverso la sperimentazione. Di seguito è riportato un framework sperimentale per decidere la quantità di dati Amazon Nova da combinare.

Seleziona un sottoinsieme rappresentativo di dati di dominio (ad esempio token 5B) e mantieni questo valore costante in tutte le esecuzioni sperimentali.

Esegui esperimenti CPT su piccola scala variando solo la quantità di dati Amazon Nova mescolati in:

- Nessuna combinazione: dominio 100% → solo dominio 5B (totale 5B)
- Miscelazione della luce: 90% dominio → dominio 5B + ~ 0,56 B Amazon Nova (totale ~ 5,56 B)
- Miscelazione media: 70% dominio → dominio 5B + ~ 2,14 B Amazon Nova (totale ~ 7,14 B)
- Mixaggio intensivo: 50% dominio → dominio 5B+5B Amazon Nova (totale 10 B)

Valuta ogni checkpoint nei benchmark di dominio in e in generale. Valuta anche il checkpoint di partenza (checkpoint Amazon Nova prima di qualsiasi formazione).

- Le prestazioni del dominio del cliente rimangono all'incirca costanti durante le esecuzioni? Di solito dovrebbe succedere, poiché ogni esecuzione ha registrato lo stesso numero di token di dominio. Se le prestazioni del dominio migliorano con una maggiore miscelazione, i dati di Amazon Nova forniscono un'utile regolarizzazione.
- I punteggi generali dei benchmark migliorano all'aumentare del mixaggio?
  - Il comportamento previsto è che le funzionalità generali dovrebbero migliorare in modo monotono man mano che vengono aggiunti più dati di Amazon Nova.
  - Misura diversi benchmark generali: MMLU (conoscenza generale), (codifica), GSM8 K HumanEval (matematica) o benchmark specifici di interesse.
- Seleziona il rapporto di miscelazione che mantiene le prestazioni del dominio offrendo al contempo funzionalità generali accettabili per i casi d'uso. Tieni conto del costo aggiuntivo della formazione con una maggiore combinazione di dati.

Una volta identificato il rapporto di miscelazione ottimale, esegui un CPT su vasta scala utilizzando il set di dati completo del dominio con il rapporto di miscelazione selezionato.

## Analisi delle categorie di miscelazione dei dati

Di seguito analizziamo ogni categoria disponibile in Data Mixing, per consentirvi di prendere la decisione migliore su quali categorie di dati abbia più senso essere rappresentate nella combinazione complessiva di dati.

## Come abilitare il data mixing

Aggiungi la `data_mixing` sezione alla tua ricetta con la distribuzione percentuale appropriata tra le categorie di set di dati. La somma `nova_data` delle percentuali deve essere 100.

### Configurazione Nova 2.0 con miscelazione dei dati

```
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

```

## Cosa significano queste categorie

Nota: Nova 2.0 include categorie aggiuntive specifiche per il ragionamento (ad esempio, `reasoning-codereasoning-math`, `reasoning-instruction-following`) che non sono disponibili in Nova 1.0.

Riepilogo delle categorie e delle etichette informative:

| Nome della categoria               | Dettagli delle informazioni                                                                                                                                                            |
|------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <code>agents</code>                | Dati di formazione incentrati sul processo decisionale autonomo, sul completamento delle attività e sul comportamento orientato agli obiettivi nei sistemi di intelligenza artificiale |
| <code>baseline</code>              | Dati linguistici fondamentali incentrati sulla comprensione generale, sulla comunicazione di base e sulle capacità linguistiche di base                                                |
| <code>chat</code>                  | Scambi conversazionali che dimostrano un flusso di dialogo naturale, il mantenimento del contesto e interazioni sociali appropriate                                                    |
| <code>code</code>                  | Codice sorgente di programmazione, documentazione e discussioni tecniche da vari linguaggi e piattaforme di programmazione.                                                            |
| <code>factuality</code>            | Materiali di riferimento e informazioni verificate incentrati sull'accuratezza, la convalida della fonte e la valutazione della verità                                                 |
| <code>identity</code>              | Quadri di personalità e modelli comportamentali incentrati su tratti caratteriali, valori e stili di interazione coerenti                                                              |
| <code>long-context</code>          | Testi estesi e narrazioni complesse incentrati sul mantenimento della coerenza e della pertinenza durante lunghi scambi                                                                |
| <code>math</code>                  | Contenuti matematici tra cui libri di testo, problemi, soluzioni e discussioni matematiche.                                                                                            |
| <code>rai</code>                   | Casi e scenari che enfatizzano i principi etici dell'IA, le considerazioni sulla sicurezza e l'implementazione responsabile della tecnologia                                           |
| <code>instruction-following</code> | Esempi di esecuzione precisa delle attività in base a diversi livelli di istruzioni e direttive dell'utente                                                                            |

| Nome della categoria            | Dettagli delle informazioni                                                                                                                |
|---------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------|
| stem                            | Contenuti tecnici riguardanti scienza, tecnologia, ingegneria e matematica, compresi concetti teorici e di risoluzione di problemi         |
| planning                        | Sequenze che dimostrano il pensiero strategico, la suddivisione delle step-by-step attività e l'allocazione efficiente delle risorse       |
| reasoning-chat                  | Scenari di dialogo analitici incentrati su discussioni logiche e flussi di conversazione strutturati                                       |
| reasoning-code                  | Sfide di programmazione e problemi algoritmici incentrati sullo sviluppo sistematico di soluzioni                                          |
| reasoning-factuality            | Scenari di valutazione delle informazioni incentrati sui processi critici di valutazione e verifica                                        |
| reasoning-instruction-following | Analisi complessa delle attività incentrata sull'interpretazione sistematica e sull'esecuzione metodica                                    |
| reasoning-math                  | Scenari matematici di risoluzione di problemi incentrati sulla progressione logica e sulle strategie di soluzione                          |
| reasoning-planning              | Scenari decisionali strategici incentrati su un approccio sistematico al raggiungimento degli obiettivi                                    |
| reasoning-rag                   | Scenari di recupero e sintesi delle informazioni incentrati sulla comprensione contestuale e sull'applicazione pertinente                  |
| reasoning-rai                   | Scenari decisionali etici incentrati sulla valutazione sistematica della sicurezza e dell'equità dell'IA                                   |
| reasoning-stem                  | Scenari scientifici di risoluzione dei problemi incentrati sull'analisi metodica e sullo sviluppo di soluzioni                             |
| rag                             | Esempi di combinazione efficace delle conoscenze esterne recuperate con le risposte generate per fornire informazioni contestuali accurate |

| Nome della categoria | Dettagli delle informazioni                                                                                                          |
|----------------------|--------------------------------------------------------------------------------------------------------------------------------------|
| translation          | Combinazioni di contenuti multilingue che mostrano una traduzione accurata preservando il contesto, il tono e le sfumature culturali |

## Guida ai parametri

- `dataset_catalog`: L'unico valore è `cpt_text_lite` per ora, finché non abilitiamo l'addestramento multimodale.
- `nova_data`: percentuale delle singole categorie di dati Nova quando vengono mescolati. Dovrebbero sommarsi fino a 1,0.
- `customer_data`: la percentuale di dati del cliente mescolati ai dati Nova.

Il numero totale di token utilizzati nella formazione può essere calcolato da  $global\_batch\_size \times max\_length \times max\_steps$

## Limitazioni

L'attuale CPT supporta solo dati di testo e non supporta alcun set di dati multimodale del cliente.

# Ottimizzazione di precisione supervisionata

## Introduzione

La regolazione fine supervisionata utilizza un set di dati con coppie di input-output per l'attività di interesse. In altre parole, fornite esempi di suggerimenti (domande, istruzioni, ecc.) insieme alle risposte corrette o desiderate e continuate ad addestrare il modello in base a queste. I pesi del modello vengono regolati per ridurre al minimo una perdita supervisionata, in genere un'entropia incrociata tra le previsioni e i token di risposta target.

## Quando usare SFT?

SFT è la soluzione migliore quando si ha un'attività ben definita con risultati chiari e desiderati. Se potete dire esplicitamente «Dato l'input X, l' correct/desired output è Y» e potete raccogliere esempi di tali mappature X-Y, allora la regolazione di precisione supervisionata è un'ottima scelta. Alcuni scenari in cui SFT eccelle includono:



- Attività di classificazione strutturate o complesse: ad esempio classificazione di documenti o contratti interni in molte categorie personalizzate. Con SFT, il modello può apprendere queste categorie specifiche molto meglio di quanto lo faccia da solo.
- Attività di risposta a domande o di trasformazione con risposte note: ad esempio la messa a punto di un modello per rispondere alle domande della knowledge base di un'azienda o per convertire i dati tra formati, in cui ogni input ha una risposta corretta.
- Coerenza di formattazione e stile: se è necessario che il modello risponda sempre in un determinato formato o tono, è possibile ottimizzare gli esempi del formato/tono corretti. Ad esempio, un corso di formazione sulle coppie di risposte rapide che dimostrano la voce o lo stile di un marchio può insegnare alla modella che utilizza quello stile nei risultati. Il comportamento che segue le istruzioni viene spesso insegnato inizialmente tramite SFT sulla base di esempi curati di buon comportamento dell'assistente.

L'SFT è il modo più diretto per insegnare a un LLM una nuova abilità o un nuovo comportamento quando è possibile specificare quale sia il comportamento giusto. Sfrutta la comprensione linguistica esistente del modello e la concentra sul vostro compito. Non utilizzate SFT quando il divario è legato alla conoscenza piuttosto che al comportamento; ciò non indurrà il modello ad apprendere nuovi fatti, gergo o eventi recenti. In questi casi, preferite una formazione preliminare continua su grandi corpora interni al dominio o la generazione potenziata dal recupero per trarre conclusioni dalle conoscenze esterne. Se è possibile misurare la qualità ma non è possibile etichettare una sola risposta corretta, è preferibile rinforzare la messa a punto con ricompense verificabili o una risposta corretta rispetto a SFT. LLM-as-judge

A seconda della complessità delle attività e delle prestazioni del modello Nova, senza alcuna ottimizzazione, è possibile pianificare da migliaia a decine di migliaia di dimostrazioni per attività, con la qualità, la coerenza e la diversità dei dati più importanti del volume grezzo.

## Quando utilizzare i parametri in modo efficiente e quando utilizzare SFT a livello completo?

Le ricette di personalizzazione Nova consentono di eseguire in modo efficiente i parametri, in particolare LoRa o SFT completo. Se desiderate un aggiornamento del modello semplice ed economico o disponete di pochissimi dati, preferite metodi efficienti in termini di parametri in modo da addestrare piccoli adattatori lasciando intatta la maggior parte della spina dorsale (l'SFT completo aggiorna tutti i parametri del modello).

## Miscelazione dei dati per SFT

Il data mixing consente di combinare i set di dati di allenamento personalizzati con i dati di formazione proprietari di Nova. Questa funzionalità è disponibile per entrambi i modelli Nova 1.0 e Nova 2.0.

Tipo di dati proprietario Nova: Nova supporta tipi di dati SFT testuali e multimodali. È organizzato in più categorie di dati, ciascuna contenente una combinazione di attività rilevanti per la categoria corrispondente.

Categorie di dati proprietarie Nova: I set di dati di testo includono diverse categorie, tra cui: processo decisionale autonomo, completamento delle attività, set di dati orientati agli obiettivi (agenti), set di dati di esecuzione delle attività precisi sia ragionati che non ragionati (reasoning-instruction-following, seguire le istruzioni), sequenze che dimostrano il pensiero strategico e la suddivisione delle step-by-step attività (pianificazione), intelligenza artificiale responsabile (rai), contesto lungo, fattualità, matematica, radice e molti altri. Allo stesso modo, i set di dati multimodali includono video, screenshot, grafici e molti altri.

La funzione di miscelazione dei dati consente di combinare i propri campioni di addestramento personalizzati con campioni dei set di dati Nova utilizzati per la messa a punto di Nova. In questo modo è possibile evitare un eccessivo adattamento della formazione personalizzata e la «catastrofica dimenticanza» delle funzionalità di Nova, oppure aiutarvi a sviluppare nuove capacità quando vi allenate da un nuovo checkpoint preaddestrato.

Per inserire i dati di Nova, devi semplicemente aggiungere un blocco `data_mixing` al file YAML della ricetta, nella sezione `training_config`. I blocchi di miscelazione di testo e dati multimodali hanno contenuti diversi. Si prega di fare riferimento alle ricette corrispondenti.

### Modelli supportati

- Nova 2.0 Lite

### Modalità supportata

- Testo
- Multimodale

## Esempi di configurazione YAML

### Esempio di configurazione 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
```

### Miscelazione di dati di testo Nova 2.0

```
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
```

## Miscelazione multimodale dei dati Nova 2.0

```
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 modello

### Checkpoint Nova 2.0

- **PRE-TRAINED [nova-lite-2/pretraining-text-RD]**: Checkpoint dopo un ritmo di apprendimento costante e fasi successive in cui il modello viene addestrato con trilioni di token. [Risultato della fase 2]
- **MID-TRAINED [nova-lite-2/pretraining-text-CE]**: consente ai clienti con volumi intermedi di dati non strutturati di introdurre i propri dati con un tasso di apprendimento più conservativo rispetto alla formazione preliminare, assorbendo conoscenze specifiche del dominio ed evitando al contempo catastrofici dimenticamenti. [Risultato della fase 3]
- **FINALE [nova-lite-2/prod]**: checkpoint finale completamente allineato che ha superato tutte le fasi di pre-allenamento e post-allenamento. [Esito della fase 4]

#### Fasi di formazione:

- Fase 1: PT Ckpt, pre-allenamento iniziale con tasso di apprendimento costante
- Fase 2: PT Ckpt, riduzione del tasso di apprendimento
- Fase 3: PT Ckpt, formazione sull'estensione del contesto
- Fase 4: formazione sulla sicurezza e sull'allineamento secondo le istruzioni

## Approcci formativi

### Guida alla selezione dell'approccio formativo

| Tipo di dati                                                    | Volume di dati | Esegui                          | Con Checkpoint                                 |
|-----------------------------------------------------------------|----------------|---------------------------------|------------------------------------------------|
| Dati di dominio grezzi non strutturati su larga scala (document | 1T+ token      | Formazione preliminare continua | Fine del tasso di apprendimento costante (CLR) |

| Tipo di dati                                                                                                                 | Volume di dati              | Esegui                                   | Con Checkpoint    |
|------------------------------------------------------------------------------------------------------------------------------|-----------------------------|------------------------------------------|-------------------|
| i, registri, articoli, codice, ecc.)                                                                                         |                             |                                          |                   |
| Dati di dominio non strutturati non strutturati su larga scala                                                               | Oltre 100 miliardi di token | A metà allenamento                       | Fine del CLR      |
| Volumi più piccoli di dati grezzi non strutturati; tracce di ragionamento strutturato/dati CoT                               | Oltre 1 miliardo di token   | A metà allenamento                       | Modello base Nova |
| Dimostrazioni strutturate (coppie input-output di alta qualità, istruzioni dettagliate sulle attività, dialoghi a più turni) | Oltre 1.000 esempi          | Ottimizzazione fine supervisionata (SFT) | Modello base Nova |

## Prerequisiti prima di iniziare

- Partiamo dal presupposto che tu abbia già configurato un cluster SMHP con un gruppo di istanze ristrette (RIG) con capacità attiva. [In caso contrario, fai riferimento qui per completare la configurazione del cluster SMHP e del RIG \[Docs Link, Workshop Link\]](#)
- Avrai bisogno di istanze EC2 p5.48xlarge per eseguire questa ricetta. Il numero minimo di istanze richiesto per eseguire questa ricetta in modo efficiente è il seguente:
  - Nova Lite 2.0 - 4 p5.48xlarge
- [Installa la SageMaker HyperPod CLI specifica di Forge utilizzando le istruzioni fornite qui](#)
- Conferma di poterti connettere al tuo cluster utilizzando `hyperpod get-clusters`
  - Nota che questo comando elencherà tutti i cluster SMHP presenti nel tuo account

- Verifica che i dati di formazione e, facoltativamente, di convalida, siano disponibili in un bucket S3 accessibile dal ruolo di esecuzione del cluster SMHP. Per la preparazione dei dati, consulta la sezione successiva.
- Completare la configurazione. Se non hai completato la configurazione, segui la [guida](#) seguente.
- Verifica: dopo aver completato la configurazione, conferma che puoi eseguire correttamente i comandi seguenti

```
aws sagemaker describe-cluster --cluster-name <cluster-name> --region <region>

hyperpod connect-cluster --cluster-name cluster-name
```

## Un approccio sistematico per ottenere un SFT di successo

- Preparazione dei dati: segui le linee guida stabilite per creare, pulire o riformattare i set di dati nella struttura richiesta. Assicurati che gli input, gli output e le informazioni ausiliarie (come tracce di ragionamento o metadati) siano allineati e formattati correttamente.
- Configurazione dell'addestramento: definisci come verrà addestrato il modello. Quando usi Amazon SageMaker HyperPod, questa configurazione è scritta in un file di ricette YAML che include:
  - Percorsi di origine dei dati (set di dati di formazione e convalida)
  - Iperparametri chiave (numero di fasi di formazione, tasso di apprendimento, dimensione del batch)
  - Componenti opzionali (parametri di allenamento distribuiti, ecc.)
  - Impostazione Data Mixing (definisce le proporzioni delle categorie di dati del cliente e di Nova)
- Ottimizza gli iperparametri SFT: i valori dei parametri della ricetta SFT che consigliamo sono un ottimo punto di partenza e una scelta affidabile. Se desideri ottimizzarli ulteriormente per il tuo caso d'uso, esegui più esecuzioni SFT con diverse combinazioni di parametri e scegli quella migliore. È possibile selezionare le combinazioni di parametri seguendo il metodo Hyper-Parameter Optimization di propria scelta. Un approccio semplice consiste nel variare il valore di un parametro (default\*0.5, default, default\*2) mantenendo un altro valore predefinito per gli altri parametri, ripetere l'operazione per ogni parametro che si desidera ottimizzare e iterare se necessario. I parametri più rilevanti per LoRa sono il tasso di apprendimento, l'alfa (parametro di scala), il numero di epoche da allenare e le fasi di riscaldamento; per il rango completo si tratta principalmente del tasso di apprendimento, del numero di epoche e delle fasi di riscaldamento.

## Sequenziamento degli esperimenti e miscelazione dei dati

- Se disponi solo di dati SFT (train/dev/test) per una serie di attività e ti interessa solo le prestazioni dei test su tali attività
  - Esegui SFT senza mixare sul checkpoint [FINAL] Nova. Utilizzate gli iperparametri SFT predefiniti e, facoltativamente, ottimizzateli per il vostro caso d'uso. Monitora le metriche di convalida, and/or valuta i checkpoint intermedi per set di dati più grandi.
- Se disponi solo di dati SFT (train/dev/test) per una serie di attività e ti interessano le prestazioni dei test su tali attività e i benchmark generali nel settore di interesse
  - Iniziate eseguendo SFT e mescolando i dati Nova su un checkpoint di pre-addestramento (checkpoint PRE-TRAINED o MID-TRAINED, non FINAL). L'utilizzo di un checkpoint intermedio consente al modello di integrare meglio i dati personalizzati con i dati proprietari di Nova, mantenendo al contempo solide funzionalità generali.
  - Esegui sessioni di formazione SFT più brevi con una quantità variabile di dati Nova (ad esempio, 10%, 25%, 50%, 75%) e selezioni di categorie di dati Nova che completano il tuo caso d'uso (ad esempio, scegli l'istruzione dopo la categoria se ti interessa la capacità di seguire le istruzioni generali). Monitora le metriche di convalida e valuta se la miscelazione aiuta le prestazioni sui benchmark generali. Seleziona il mix di allenamento e il checkpoint che consentono di ottenere la migliore combinazione di prestazioni relative all'attività e prestazioni generali. A seconda del caso d'uso, sia le prestazioni operative che quelle generali possono essere ulteriormente migliorate utilizzando il Reinforcement Fine Tuning (RFT).

## Preparare il set di dati per SFT

Nova 2.0: [utilizza il formato API Converse -inference-call.html. https://docs.aws.amazon.com/bedrock/latest/userguide/conversation](https://docs.aws.amazon.com/bedrock/latest/userguide/conversation.html) Il formato dati Nova 2.0 può contenere campi di ragionamento aggiuntivi: [https://docs.aws.amazon.com/bedrock/latest/APIReference/API\\_runtime\\_.html](https://docs.aws.amazon.com/bedrock/latest/APIReference/API_runtime_.html) [ReasoningContentBlock](#)

Il contenuto del ragionamento cattura le fasi di pensiero intermedie del modello prima di generare una risposta finale. A assistant sua volta, usa il `reasoningContent` campo per includere tracce di ragionamento. Usa testo semplice per ragionare i contenuti, evita i tag di markup come `<thinking>` e `</thinking>` meno che non sia specificamente richiesto dall'attività e assicurati che il contenuto del ragionamento sia chiaro e pertinente al processo di risoluzione dei problemi.



# Metodi di valutazione

## Prerequisiti

- Checkpoint S3 dal `manifest.json` file del processo di formazione (per i modelli addestrati)
- Set di dati di valutazione caricato su S3 nel formato corretto
- Percorso S3 di output per i risultati della valutazione

Benchmark pronti all'uso: utilizza i benchmark predefiniti per convalidare le prestazioni relative alle attività generali. [Per maggiori dettagli, consulta questa pagina: -hp-evaluate.html https://docs.aws.amazon.com/sagemaker/latest/dg/nova](https://docs.aws.amazon.com/sagemaker/latest/dg/nova-hp-evaluate.html)

## Porta i tuoi dati

Puoi anche fornire i tuoi dati personalizzati formattandoli nel formato seguente e quindi utilizzando i contenitori indicati di seguito per ottenere risultati di inferenza insieme alle probabilità di registro per le calibrazioni, se necessario.

Crea jsonl per attività con la seguente struttura:

```
{
 "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"
}
```

Gli output generati durante la fase di inferenza del lavoro di valutazione avranno la seguente struttura:

```
{
 "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'}"
}
```

Descrizioni dei campi:

- **prompt**: input formattato inviato al modello
- **inference**: risposta generata dal modello
- **gold**: Risposta corretta prevista dal set di dati di input, campo di risposta dall'input
- **metadata**: metadati opzionali trasmessi dall'input

## Preparare la configurazione di valutazione

Comando per avviare il processo di valutazione. Si usa `--override-parameters` per modificare qualsiasi voce della ricetta.

```
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"
 }'
```

## Best practice

- Dai priorità alla qualità dei dati rispetto al volume: i dati di formazione di alta qualità, diversificati e rappresentativi sono più preziosi di grandi quantità di dati di bassa qualità.
- Includi reasoning-instruction-following categoria: quando utilizzi la combinazione di dati, includi la categoria "reasoning-instruction-following" per mantenere elevate prestazioni generiche tra le attività.

- Usa i tassi di apprendimento predefiniti: inizia con i tassi di apprendimento predefiniti (1e-5 per LoRa, 5e-6 per SFT di livello completo) e modifica solo se necessario in base alle metriche di convalida.
- Mixaggio di dati Balance Nova: mescola un massimo del 50% di dati Nova per un equilibrio ottimale tra latenza e prestazioni. Percentuali più elevate possono migliorare le capacità generali ma possono aumentare i tempi di formazione.
- Monitora le metriche di convalida: valuta regolarmente i checkpoint intermedi durante l'allenamento per rilevare tempestivamente il sovradimensionamento o il degrado delle prestazioni.
- Esegui test su set di dati rappresentativi: assicurati che i set di dati di valutazione rappresentino accuratamente i casi d'uso di produzione per una valutazione significativa delle prestazioni.

## Preparare Training Job Config

### Parametri Hyper

Set completo di iperparametri diversi dalla miscelazione dei dati:

```
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. 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: s3://my-bucket-name/outputs/ # 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

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 # This parameter suggests after how many training steps the
checkpoints will be saved. Should be less than or equal to max_steps(please override
this value with a numerical value equal or less than max_steps value; 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)

```

I parametri più rilevanti per LoRa sono il tasso di apprendimento, l'alfa (parametro di scala), il numero di epoche da allenare e le fasi di riscaldamento; per il livello completo si tratta principalmente del tasso di apprendimento, del numero di epoche e delle fasi di riscaldamento. Le ricette sono precompilate con le impostazioni predefinite consigliate.

## Configura Data Mixing Block

Aggiungi la sezione `data_mixing` alla tua ricetta con la distribuzione percentuale appropriata tra le categorie di set di dati.

Di seguito descriviamo ogni categoria di dati Nova disponibile.

## Configurazione Nova 2.0 con miscelazione dei dati

```
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
categories below 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
```

## Cosa significano queste categorie?

### Categorie di dati di testo Nova 2.0

| Nome della categoria      | Dettagli delle informazioni                                                                                                                                                            |
|---------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| agenti                    | Dati di formazione incentrati sul processo decisionale autonomo, sul completamento delle attività e sul comportamento orientato agli obiettivi nei sistemi di intelligenza artificiale |
| della deviazione del bias | Dati linguistici fondamentali incentrati sulla comprensione generale, sulla comunicazione di base e sulle capacità linguistiche di base                                                |
| chat                      | Scambi conversazionali che dimostrano un flusso di dialogo naturale, il mantenimento del contesto e interazioni sociali appropriate                                                    |
| code                      | Codice sorgente di programmazione, documentazione e discussioni tecniche da vari linguaggi e piattaforme di programmazione.                                                            |
| fattualità                | Materiali di riferimento e informazioni verificati e incentrati sull'accuratezza, la convalida della fonte e la valutazione della verità                                               |
| identità                  | Quadri di personalità e modelli comportamentali incentrati su tratti caratteriali, valori e stili di interazione coerenti                                                              |
| contesto a lungo termine  | Testi estesi e narrazioni complesse incentrati sul mantenimento della coerenza e della pertinenza durante lunghi scambi                                                                |
| matematica                | Contenuti matematici tra cui libri di testo, problemi, soluzioni e discussioni matematiche.                                                                                            |

| Nome della categoria            | Dettagli delle informazioni                                                                                                                  |
|---------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------|
| pioggia                         | Casi e scenari che enfatizzano i principi etici dell'IA, le considerazioni sulla sicurezza e l'implementazione responsabile della tecnologia |
| seguendo le istruzioni          | Esempi di esecuzione precisa delle attività in base a diversi livelli di istruzioni e direttive dell'utente                                  |
| radice                          | Contenuti tecnici riguardanti scienza, tecnologia, ingegneria e matematica, compresi concetti teorici e di risoluzione di problemi           |
| pianificazione                  | Sequenze che dimostrano il pensiero strategico, la suddivisione delle step-by-step attività e l'allocazione efficiente delle risorse         |
| chat di ragionamento            | Scenari di dialogo analitici incentrati su discussioni logiche e flussi di conversazione strutturati                                         |
| codice di ragionamento          | Sfide di programmazione e problemi algoritmici incentrati sullo sviluppo sistematico di soluzioni                                            |
| ragionamento-fattualità         | Scenari di valutazione delle informazioni incentrati sui processi critici di valutazione e verifica                                          |
| reasoning-instruction-following | Analisi complessa delle attività incentrata sull'interpretazione sistematica e sull'esecuzione metodica                                      |
| ragionamento matematico         | Scenari matematici di risoluzione di problemi incentrati sulla progressione logica e sulle strategie di soluzione                            |

| Nome della categoria            | Dettagli delle informazioni                                                                                                                    |
|---------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------|
| pianificazione del ragionamento | Scenari decisionali strategici incentrati su un approccio sistematico al raggiungimento degli obiettivi                                        |
| straccio di ragionamento        | Scenari di recupero e sintesi delle informazioni incentrati sulla comprensione contestuale e sull'applicazione pertinente                      |
| razionamento-rai                | Scenari decisionali etici incentrati sulla valutazione sistematica della sicurezza e dell'equità dell'IA                                       |
| stelo di ragionamento           | Scenari scientifici di risoluzione dei problemi incentrati sull'analisi metodica e sullo sviluppo di soluzioni                                 |
| straccio                        | Esempi di come combinare efficacemente le conoscenze esterne recuperate con le risposte generate per fornire informazioni contestuali accurate |
| traduzione                      | Combinazioni di contenuti multilingue che mostrano una traduzione accurata preservando il contesto, il tono e le sfumature culturali           |

## Miscelazione multimodale dei dati (Nova 2.0)

```

data_mixing:
 dataset_catalog: sft_1p5_mm_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
categories below 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
```

Nota: Nova 2.0 include il supporto per categorie di dati video che non è disponibile in Nova 1.0.

Cosa significano queste categorie?

Categorie di dati multimodali Nova 2.0

| Nome della categoria | Dettagli delle informazioni                                                                                                                                                                                                                            |
|----------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| grafici              | Rappresentazioni visive e descrizioni di grafici, diagrammi a torta, grafici a barre, grafici a linee e altre visualizzazioni statistiche per aiutare il modello a comprendere e comunicare le informazioni quantitative in modo efficace              |
| chat                 | Dati conversazionali abbinati a elementi visivi incentrati sulla comprensione del dialogo contestuale e sulle interazioni basate sulle immagini                                                                                                        |
| code                 | Interfacce di programmazione e ambienti di sviluppo incentrati sull'interpretazione visiva del codice, schermate IDE e diagrammi tecnici                                                                                                               |
| documenti            | Dati incentrati sui documenti che combinano testo, immagini, layout e formattazione per addestrare i modelli alla comprensione e all'elaborazione di vari tipi e strutture di documenti e facilitare concetti come il riconoscimento dei contenuti PDF |

| Nome della categoria | Dettagli delle informazioni                                                                                                                                                      |
|----------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| general              | Contenuti visivo-testuali diversificati incentrati sull'ampia comprensione di immagini, grafica e testo descrittivo di accompagnamento                                           |
| grounding            | Materiali di riferimento visivi e immagini etichettate incentrati sul collegamento dei concetti linguistici alle rappresentazioni visive del mondo reale                         |
| straccio             | Esempi di recupero multimodale che mostrano come combinare e fare riferimento in modo efficace a conoscenze esterne visive e testuali per generare risposte contestuali accurate |
| screenshot           | acquisizioni dell'interfaccia applicativa e immagini di visualizzazione digitale incentrate sulla comprensione delle interfacce software e delle interazioni digitali            |
| testo                | Un pool bilanciato di dati di testo contestuali creato dalle categorie di set di dati SFT Nova di solo testo per fornire competenze generaliste                                  |
| traduzione           | Contenuti visivi multilingue incentrati sull'interpretazione multilingue del testo nelle immagini e negli elementi visivi culturali                                              |
| video                | Contenuti visivi basati sul movimento incentrati sulla comprensione temporale e sulla comprensione narrativa-visiva sequenziale                                                  |

## Come avviare un lavoro

Puoi anche fare riferimento al README, se hai solo bisogno di ottenere i dettagli essenziali per dare il via alla prima esecuzione di SFT.

## Informazioni sul contenitore:

## Informazioni sul contenitore e comandi di avvio

| Modello  | Tecnica     | Sottocategoria        | URI immagine                                                                                              | Comando Hyperpod Launcher                                                                                                                                                                                                                                                           |
|----------|-------------|-----------------------|-----------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Nova 2.0 | Fine-tuning | Testo SFT             | 708977205387.dkr.ecr.us-east-1.amazonaws.com/:SM-HP-SFT-V2-Più recente nova-fine-tune-repo                | hyperpod start-job\ -n kubeflow \ --recipe fine-:SM-HP-SFT-V2-più recente»}'tuning/nova/nova_2_0/nova_lite/SFT/nova_lite_2_0_p5_gpu_sft \ --override-parameters '{ "instance_type": "ml.p5.48xlarge", "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/novafine-tune-repo |
| Nova 2.0 | Fine-tuning | SFT Text + Datamixing | 708977205387.dkr.ecr.us-east-1.amazonaws.com/:SM-HP-SFT-V2-Datamixing-Ultima versione nova-fine-tune-repo | hyperpod start-job\ -n kubeflow \ --recipe fine-:SM-HP-SFT-V2-DataMixing-Ultima versione»} 'tuning/nova/forgeno/nova_2_0                                                                                                                                                            |

| Modello | Tecnica | Sottocategoria | URI immagine | Comando Hyperpod Launcher                                                                                                                                                                                                                                                                 |
|---------|---------|----------------|--------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
|         |         |                |              | <pre>/nova_lite/SFT/<br/>nova_lite_2_<br/>0_p5_gpu_<br/>sft_text_<br/>with_datamix \ --<br/>override-paramet<br/>ers '{ "instance<br/>_type": "ml.p5.48<br/>xlarge",<br/>"container":<br/>"70897720<br/>5387.dkr.ecr.us-<br/>east-1.amaz<br/>onaws.com/<br/>novafine-tune-<br/>repo</pre> |

| Modello  | Tecnica     | Sottocategoria | URI immagine                                                                                | Comando Hyperpod Launcher                                                                                                                                                                                                                                                           |
|----------|-------------|----------------|---------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Nova 2.0 | Fine-tuning | 4 MM           | 708977205387.dkr.ecr.us-east-1.amazonaws.com /:SM-HP-SFT-V2-Più recente nova-fine-tune-repo | hyperpod start-job\ -n kubeflow \ --recipe fine-:SM-HP-SFT-V2-più recente»}'tuning/nova/nova_2_0/nova_lite/SFT/nova_lite_2_0_p5_gpu_sft \ --override-parameters '{ "instance_type": "ml.p5.48xlarge", "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/novafine-tune-repo |

| Modello  | Tecnica     | Sottocategoria             | URI immagine                                                                                              | Comando Hyperpod Launcher                                                                                                                                                                                                                                                                                                  |
|----------|-------------|----------------------------|-----------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Nova 2.0 | Fine-tuning | Miscelazione dati SFT MM + | 708977205387.dkr.ecr.us-east-1.amazonaws.com/:SM-HP-SFT-V2-Datamixing-Ultima versione nova-fine-tune-repo | hyperpod start-job\ -n kubeflow \ --recipe fine-:SM-HP-SFT-V2-DataMixing-Ultima versione» } 'tuning/nova/forge/nova_2_0/nova_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/novafine-tune-repo |

Una volta completata la configurazione, partendo dalla radice del repository, vai alla cartella delle ricette nova sft predefinita sagemaker-hyperpod-cli

- `cd//src/hyperpod_cli/sagemaker_hyperpod_recipes/recipes_collection/recipes/training/nova`
- Qui puoi scegliere se eseguire le ricette nova 1 o nova 2 in base alla scelta del modello base.

Per Nova 2.0 sft:

- Se desideri utilizzare un normale lavoro sft, dovresti essere in grado di vedere una ricetta in questa cartella
  - `cd/src/hyperpod_cli/sagemaker_hyperpod_recipes/recipes_collection/recipes/fine-tuning/nova_2_0/nova_lite/SFTE` poi dovresti essere in grado di vedere una ricetta in questa cartella chiamata `nova_lite_2_0_p5x8_gpu_sft.yaml`
- Se desideri utilizzare datamixing sft Job, puoi accedere alla cartella delle ricette di sft Forge
  - `cd/src/hyperpod_cli/sagemaker_hyperpod_recipes/recipes_collection/recipes/fine-tuning/nova/forge/nova_2_0/nova_lite/SFTE` dovresti essere in grado di vedere una ricetta in questa cartella chiamata: `nova_lite_2_0_p5x8_gpu_sft_with_datamix.yaml`
- Modifica le sezioni della ricetta richieste dal lavoro, come `name`, `data_s3_path`, `validation_s3_path`, `output_s3_path` e `max_steps`. Dato che stiamo eseguendo sft, la nozione di epoche non si applica qui.

La configurazione di miscelazione dei dati avrà lo stesso aspetto, ma con una sezione aggiuntiva di miscelazione dei dati nella parte inferiore simile a questa

```
data_mixing:
 dataset_catalog: sft_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: 20
 scientific: 20
 code: 20
 factual-and-news: 20
 longform-text: 0
 health-and-medicine: 0
 humanities-and-education: 0
 legal: 0
 math: 0
 additional-languages: 0
 social-and-personal-interest: 0
 entertainment: 0
 reasoning: 0
 other: 0
 tables: 0
```

```
customer_data: # percent input of customer data. 100 = use only customer data, 0 =
use only the nova_data mix above
percent: 25
```

Qui ci sono due categorie di dati di primo livello:

- **nova\_data:** Questa è l'effettiva miscelazione dei dati ed è suddivisa in ancora più categorie. È imperativo che si sommino fino al 100%
  - Di seguito è riportata una ripartizione completa di queste categorie, incluso il numero di token
- **customer\_data:** Questi sono i tuoi dati di allenamento a cui si fa riferimento nella chiave `data_s3_path` nella parte superiore di `yaml`. La percentuale qui fornita determina quale sarà la percentuale risultante per `nova_data`. Ad esempio, nelle selezioni percentuali precedenti, durante la formazione utilizzeremo il 25% di `customer_data` e il 75% di `nova_data`, di cui il 15% saranno agenti, il 15%, il 15% sarà scientifico business-and-finance, il 15% sarà codice e il 15% sarà factual-and-news

Suggerimento: esegui `pip install -e.` ancora una volta e sei pronto per inviare il tuo lavoro!

Qui sovrascriveremo un paio di parametri per utilizzare la miscelazione dei dati:

```
hyperpod start-job \
-n kubeflow \
--recipe fine-tuning/nova/forging/nova_2_0/nova_lite/SFT/
nova_lite_2_0_p5x8_gpu_sft_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-Datamix",
"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/
}'
```

L'output dovrebbe contenere un nome di lavoro come segue:

```
MY Desktop # % hyperpod start-job \
-n kubeflow \
```



```
--recipe training/nova/forgeno/nova_2_0/nova_lite/sft/
nova_lite_2_0_p5x8_gpu_pretrain_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-Datamix",
 "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/
}'
```

L'output sarebbe simile a questo:

```
Final command: python3 /local/home/my/Downloads/sagemaker-hyperpod-cli/
src/hyperpod_cli/sagemaker_hyperpod_recipes/main.py recipes=training/nova/
nova_micro_p5x8_gpu_pretrain cluster_type=k8s cluster=k8s base_results_dir=/local/home/
niphaded/Downloads/sagemaker-hyperpod-cli/results cluster.pullPolicy="IfNotPresent"
cluster.restartPolicy="OnFailure" cluster.namespace="kubeflow"
instance_type="p5d.48xlarge" container="900867814919.dkr.ecr.us-east-1.amazonaws.com/
nova-fine-tune-repo:sft-datamix-rig-final"
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/niphaded-sft-run-wzdyn_launch.sh
Running Helm script: /local/home/my/Downloads/sagemaker-hyperpod-cli/results/my-sft-
run-wzdyn/niphaded-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"
}
```

Puoi visualizzare lo stato del tuo lavoro usando `hyperpod list-pods -n kubeflow --job-name my-sft-run-wzdyn`

```
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"
 }
]
}
```

oppure usa direttamente il comando `kubectl` per trovarli.

Ad esempio,

```
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>         |

Suggerimento: assicurati di usare sempre il flag `-o wide` poiché il nodo EKS su cui viene eseguito il job ti aiuterà a trovare i log ancora più velocemente nell'interfaccia utente AWS

## Come monitorare Job

Puoi visualizzare i tuoi registri in tre modi:

### a) Utilizzo CloudWatch

I tuoi log sono disponibili nel tuo account Amazon Web Services che contiene il cluster hyperpod in. CloudWatch Per visualizzarli nel browser, vai alla CloudWatch home page del tuo account e cerca il nome del cluster. Ad esempio, se il cluster fosse chiamato, my-hyperpod-rig il gruppo di log avrebbe il prefisso:

- Gruppo di log: /aws/sagemaker/Clusters/my-hyperpod-rig/ {UUID}
- Una volta entrato nel gruppo di log, puoi trovare il log specifico utilizzando l'ID dell'istanza del nodo, ad esempio hyperpod-i-00b3d8a1bf25714e4.
  - i-00b3d8a1bf25714e4 rappresenta qui il nome del computer compatibile con hyperpod su cui è in esecuzione il processo di formazione. Ricordiamo come nel comando precedente `kubectl get pods -o wide -w -n kubeflow | (head -n1; grep)` output abbiamo catturato una colonna chiamata NODE. my-cpt-run
  - L'esecuzione del nodo «master» era in questo caso in esecuzione su hyperpod-i-00b3d8a1bf25714e4 e quindi useremo quella stringa per selezionare il gruppo di log da visualizzare. Seleziona SagemakerHyperPodTrainingJob quello che dice /rig-group/ [NODE]

I tuoi log dovrebbero avere un aspetto simile a questo:

### b) Utilizzo CloudWatch di Insights

Se hai il nome del tuo lavoro a portata di mano e non desideri seguire tutti i passaggi precedenti, puoi semplicemente interrogare tutti i log in /aws/sagemaker/Clusters/my-hyperpod-rig/ {UUID} per trovare il registro individuale.

CPT

```
fields @timestamp, @message, @logStream, @log
| filter @message like /(?!i)Starting CPT Job/
| sort @timestamp desc
```

```
| limit 100
```

Per il completamento del lavoro, sostituire Starting SFT Job con SFT Job completato

Quindi puoi fare clic sui risultati e scegliere quello che dice «Epoch 0" poiché sarà il tuo nodo principale.

## C) Usare la cli aws

Puoi scegliere di tracciare i tuoi log usando il. Prima di farlo, controlla la tua versione di aws cli usando `aws --version`. Si consiglia inoltre di utilizzare questo script di utilità che aiuta a tracciare i log in tempo reale nel terminale

per V1:

```
aws logs get-log-events \
 --log-group-name /aws/sagemaker/YourLogGroupName \
 --log-stream-name YourLogStream \
 --start-from-head | jq -r '.events[].message'
```

per V2:

```
aws logs tail /aws/sagemaker/YourLogGroupName \
 --log-stream-name YourLogStream \
 --since 10m \
 --follow
```

## D) Configurare ML Flow:

Puoi tenere traccia delle metriche tramite MLFlow.

Crea un'app MLflow

Utilizzo dell'interfaccia utente di Studio: se crei un lavoro di formazione tramite l'interfaccia utente di Studio, viene creata automaticamente MLflow un'app predefinita e selezionata per impostazione predefinita in Opzioni avanzate.

Utilizzo della CLI: se utilizzi la CLI, devi creare un' MLflow app e passarla come input alla richiesta API del lavoro di formazione.

```
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)
```

## Accedi all'app MLflow

Utilizzo della CLI: crea un URL predefinito per accedere all'interfaccia utente dell' MLflow app:

```
aws sagemaker create-presigned-mlflow-app-url \
 --arn $mlflow_app_arn \
 --region $region \
 --output text
```

Una volta configurato ML Flow, puoi passare l'URI nella tua ricetta o utilizzare override all'avvio del lavoro. Un esempio di come farlo può essere trovato in README.

## Come valutare il modello dopo SFT?

### Prerequisiti

- URI Checkpoint S3 dal file manifest.json del tuo processo di formazione (per modelli addestrati)
- Set di dati di valutazione caricato su S3 nel formato corretto
- Percorso S3 di output per i risultati della valutazione

Benchmark pronti all'uso: utilizza i benchmark predefiniti per convalidare le prestazioni relative alle attività generali. Per maggiori dettagli, consulta [qui](#).

## Porta i tuoi dati:

Puoi anche fornire i tuoi dati personalizzati formattandoli nel formato seguente e quindi utilizzando i contenitori indicati di seguito per ottenere risultati di inferenza insieme alle probabilità di registro per le calibrazioni, se necessario.

Crea jsonl per task con la seguente struttura:

```
{
 "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"
}
```

Gli output generati durante la fase di inferenza del lavoro di valutazione avranno la seguente struttura:

```
{
 "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'}"
}
```

Descrizioni dei campi:

- prompt: input formattato inviato al modello
- inferenza: risposta generata dal modello
- gold: risposta corretta prevista dal set di dati di input, campo di risposta dall'input
- metadati: metadati opzionali trasmessi dall'input

## Preparare la configurazione di valutazione

Comando per avviare il processo di valutazione. Usa «--override-parameters» per modificare qualsiasi voce della ricetta.

```
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"
 }'
```

Lancia il tuo Job di valutazione

Comandi di avvio del lavoro per diverse ricette con immagini corrispondenti.

Comandi Evaluation Job Launch

| Modello  | Tecnica     | Sottocategoria | URI immagine                                                                          | Comando                                                                                                                                                                                                                                                  |
|----------|-------------|----------------|---------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Nova 2.0 | Valutazione | Valutazione    | 708977205387.dkr.ecr.us-east-1.amazonaws.com /:SM-HP-Eval-Latest nova-evaluation-repo | hyperpod start-job -n kubeflow\ --recipe -evaluation-repo:sm-hp-eval-latest}> 'evaluation/nova/nova_2_0/nova_lite/nova_lite_2_0_p5_48xl_gpu_ft_eval \ --override-parameters '{ "instance_type": "ml.p5.48xlarge", "container": "708977205387.dkr.ecr.us- |

| Modello | Tecnica | Sottocategoria | URI immagine | Comando                       |
|---------|---------|----------------|--------------|-------------------------------|
|         |         |                |              | east-1.amaz<br>onaws.com/nova |

## Lezioni apprese e suggerimenti

- La qualità del set di dati SFT è fondamentale. È necessario fare ogni sforzo per filtrare i dati di bassa qualità. Se disponi di un piccolo sottoinsieme di dati di eccezionale qualità, in termini sia di complessità che di precisione, potresti considerare di collocarli verso la fine del corso di formazione per aiutare il modello a convergere meglio.
- Utilizziamo set di dati testuali e multimodali (MM) per la miscelazione dei dati. I nostri esperimenti con set di dati di testo mostrano che l'aggiunta della categoria "reasoning-instruction-following" proprietaria di Nova migliora significativamente le prestazioni rispetto ai benchmark generici. Ti consigliamo di includere questa categoria nella tua strategia di miscelazione dei dati se ti interessa un benchmark generico che viene regredito dopo aver eseguito SFT con i tuoi set di dati.
- Per quanto riguarda i set di dati MM, i nostri esperimenti indicano che incorporare oltre il 20% delle categorie di video nel mix è vantaggioso per mantenere le prestazioni dei benchmark generici.
- Inoltre, l'SFT con miscelazione dei dati è piuttosto sensibile al tasso di apprendimento, quindi la nostra scoperta suggerisce di ottimizzarla con il tasso di apprendimento predefinito, ovvero 1e-5 per LoRa e 5e-6 per FR.
- Infine, c'è un compromesso tra latenza e prestazioni se si combinano set di dati proprietari di Nova, quindi i nostri risultati suggeriscono di mescolare il 50% al massimo per un buon equilibrio.

## Apprendimento per rinforzo

### Note

La documentazione dettagliata viene fornita una volta sottoscritta

Nova Forge offre funzionalità avanzate di reinforcement learning con la possibilità di utilizzare funzioni di ricompensa remota nel proprio ambiente. I clienti possono scegliere di integrare il proprio endpoint per eseguire la convalida per un feedback immediato nel mondo reale, o persino utilizzare il proprio orchestratore per coordinare le valutazioni agentiche a più turni nel proprio ambiente.



## Porta il tuo orchestratore personale per valutazioni agentiche a più turni

Per gli utenti di Forge che richiedono conversazioni a più turni o funzioni di ricompensa che superano i timeout di 15 minuti, Nova Forge offre funzionalità Bring Your Own Orchestration (BYOO). Ciò consente di coordinare le valutazioni agentiche su più turni nel proprio ambiente (ad esempio, utilizzando strumenti chimici per valutare i progetti molecolari o simulazioni robotiche che premiano il completamento efficiente delle attività e penalizzano le collisioni).

### Argomenti

- [Panoramica dell'architettura](#)
- [Configurazione ed esecuzione](#)

### Panoramica dell'architettura

L'architettura BYOO offre il pieno controllo del processo di implementazione e generazione attraverso un'infrastruttura gestita dal cliente.

#### Formazione VPC:

- Rollout: coordina la formazione delegando la generazione del rollout all'infrastruttura del cliente
- Trainer: esegue aggiornamenti sul peso del modello in base alle implementazioni ricevute

#### VPC del cliente (ad esempio ECS su EC2):

- Proxy Lambda: riceve le richieste di implementazione e si coordina con l'infrastruttura del cliente
- Rollout Response SQS: coda per la restituzione delle implementazioni completate all'infrastruttura di formazione
- Generate Request SQS: coda per le richieste di generazione di modelli
- Generate Response SQS: coda per le risposte di generazione del modello
- Customer Container: implementa una logica di orchestrazione personalizzata (può utilizzare lo starter kit fornito)
- DynamoDB: archivia e recupera lo stato durante il processo di orchestrazione

#### Flusso di lavoro:

1. Rollout delega la generazione del rollout a Proxy Lambda

2. Proxy Lambda invia la richiesta API di rollout a Generate Request SQS
3. Il contenitore del cliente elabora le richieste, gestisce le interazioni a più turni e richiama le funzioni di ricompensa
4. Il contenitore archivia e recupera lo stato da DynamoDB in base alle esigenze
5. Container invia le risposte di rollout a Rollout Response SQS
6. Rollout invia le implementazioni completate a Trainer per l'aggiornamento del peso

## Configurazione ed esecuzione

Per istruzioni di configurazione dettagliate, configurazioni delle ricette, formati di richiesta e risposta ed esempi di ambiente, consultate la documentazione riservata fornita agli abbonati di Nova Forge. Per ottenere i documenti di Nova Forge, procedi nel seguente modo:

```
aws s3 cp s3://nova-forge-c7363-206080352451-us-east-1/v1/ ./ --recursive
```

Una volta scaricate le risorse, puoi trovare tutta la documentazione nella docs cartella.

## Toolkit AI responsabile e moderazione dei contenuti

### Toolkit di intelligenza artificiale responsabile

Nova Forge fornisce un Responsible AI Toolkit che include dati di formazione e valutazione per allineare i modelli alle linee guida sull'intelligenza artificiale responsabile di Amazon Nova durante il processo di formazione e controlli di runtime per moderare le risposte del modello durante l'inferenza.

**Dati di formazione:** sono disponibili casi e scenari che enfatizzano i principi dell'intelligenza artificiale responsabile, le considerazioni sulla sicurezza e l'implementazione responsabile della tecnologia per la miscelazione dei dati al fine di allineare i modelli in modo responsabile durante la formazione continua.

**Valutazioni:** le valutazioni che testano la capacità del modello di rilevare e rifiutare contenuti inappropriati, dannosi o errati sono disponibili come attività di riferimento per determinare il delta tra le prestazioni del modello di base e le prestazioni del modello personalizzato.

**Controlli di runtime:** per impostazione predefinita, il runtime di Amazon Nova controlla le risposte moderate del modello durante l'inferenza. Per modificare questi controlli di runtime, richiedi le

impostazioni di moderazione dei contenuti personalizzabili di Amazon Nova contattando un AWS account manager.

La sicurezza è una responsabilità condivisa tra AWS i suoi utenti. La modifica del modello di base o l'utilizzo di corsi di formazione continua per migliorare le prestazioni in un caso d'uso specifico possono influire sulla sicurezza, sull'equità e su altre proprietà del nuovo modello. Un metodo di adattamento robusto riduce al minimo le modifiche alla sicurezza, all'equità e ad altre protezioni integrate nei modelli base, riducendo al minimo l'impatto sulle prestazioni del modello per attività per le quali il modello non è stato personalizzato. End-to-end è necessario testare le applicazioni su set di dati rappresentativi dei casi d'uso per determinare se i risultati dei test soddisfano le aspettative specifiche di sicurezza, equità e altre proprietà, nonché l'efficacia complessiva. Per ulteriori informazioni, consulta la Guida all'uso responsabile dell'IA di Amazon Web Services, la Politica sull'IA responsabile di Amazon Web Services, la Politica di utilizzo accettabile di Amazon Web Services e i Termini del servizio di Amazon Web Services.

# Uso responsabile

Costruire misure di sicurezza, protezione e fiducia con modelli di intelligenza artificiale è una responsabilità condivisa tra AWS i nostri clienti. Il nostro obiettivo è allineare i modelli alla [Policy di utilizzo accettabile di AWS](#) e mitigare gli esiti indesiderati offrendo al contempo un'esperienza piacevole al cliente. Il nostro approccio all'IA responsabile (RAI) è strutturato attorno alle nostre [dimensioni fondamentali dell'IA responsabile](#), che sono trattate nel seguente elenco. Per ognuna di queste dimensioni, abbiamo sviluppato linee guida che regolano il nostro processo decisionale durante l'intero ciclo di vita dello sviluppo del modello. Questo ciclo di vita comprende ogni fase, dalla raccolta iniziale dei dati e dall'addestramento preliminare, alla messa in funzione delle mitigazioni del runtime post-implementazione.

- **Equità:** considerare l'impatto sui diversi gruppi di parti interessate
- **Spiegabilità:** comprendere e valutare gli output di sistema
- **Privacy e sicurezza:** acquisizione, utilizzo e protezione appropriati di dati e modelli
- **Sicurezza:** prevenire gli output dannosi e l'uso improprio
- **Controllabilità:** disporre di meccanismi per monitorare e guidare il comportamento del sistema IA
- **Veridicità e robustezza:** ottenere output di sistema corretti, anche con input imprevisti o contraddittori
- **Governance:** integrazione delle migliori pratiche nella catena di fornitura dell'IA, compresi fornitori e responsabili dell'implementazione
- **Trasparenza:** consentire alle parti interessate di fare scelte informate sul loro coinvolgimento con un sistema di intelligenza artificiale

## Linee guida

Le linee guida che utilizziamo per indirizzare lo sviluppo del nostro modello includono, a titolo esemplificativo ma non esaustivo, la moderazione di contenuti che esaltano, facilitano o promuovono quanto segue:

- Partecipazione ad attività pericolose, autolesionismo o uso di sostanze pericolose.
- Uso, abuso o commercio di sostanze controllate, tabacco o alcol.
- Violenza fisica.
- Materiale pedofilo o pedopornografico.

- Abuso o traffico di animali.
- Disinformazione che attribuisce a individui o gruppi la responsabilità di inganni intenzionali, di minare un'istituzione che gode di una credibilità pubblica generale o di mettere in pericolo la salute umana o i mezzi di sussistenza.
- Malware, contenuti dannosi o qualsiasi contenuto che faciliti la criminalità informatica.
- Mancanza di rispetto, discriminazione o stereotipizzazione nei confronti di un individuo o di un gruppo.
- Insulti, parolacce, gesti osceni, linguaggio sessualmente esplicito, pornografia, simboli di odio o gruppi di odio.
- Nudità completa che non rientra in un contesto scientifico, educativo o di riferimento.
- Pregiudizio nei confronti di un gruppo basato su una caratteristica demografica.

## Raccomandazioni

Adeguatezza all'uso: poiché gli output del modello IA sono probabilistici, Amazon Nova può produrre contenuti imprecisi o inappropriati. I clienti devono valutare gli output per verificarne l'accuratezza e l'adeguatezza per il loro caso d'uso, soprattutto se verranno mostrati direttamente agli utenti finali. Inoltre, se Amazon Nova viene utilizzato nei flussi di lavoro dei clienti che producono decisioni consequenziali, i clienti devono valutare i potenziali rischi del loro caso d'uso e implementare la supervisione umana appropriata, i test e altre misure di sicurezza specifiche dei casi d'uso per mitigare tali rischi.

Ottimizzazioni dei prompt: in caso di moderazione da parte di Amazon Nova, valuta la possibilità di esaminare i prompt utilizzati rispetto alle linee guida riportate sopra. L'ottimizzazione dei prompt per ridurre la probabilità di generare risultati indesiderati è la strategia consigliata per produrre gli output previsti utilizzando i modelli Amazon Nova. Presta attenzione ai punti in cui l'input è controllato dagli utenti, compresi i contenuti in pixel che potrebbero influire sulle prestazioni del modello. Per ulteriori dettagli, consulta la sezione relativa alle linee guida sui prompt di questa guida per l'utente.

Privacy: Amazon Nova è disponibile in Amazon Bedrock. Amazon Bedrock è un servizio gestito e non memorizza né esamina le richieste dei clienti o il completamento delle richieste dei clienti e le istruzioni e i completamenti non vengono mai condivisi tra clienti o partner. Amazon Bedrock AWS non utilizza input o output generati dal Amazon Bedrock servizio per addestrare Amazon Bedrock modelli, incluso Amazon Nova. Per ulteriori informazioni, consulta la Sezione [50.3](#) dei Termini di AWS servizio e le [domande frequenti sulla privacy AWS dei dati](#). Per informazioni sulla privacy specifiche del servizio, consulta la sezione Privacy e sicurezza della documentazione. [Amazon Bedrock FAQs](#)

Amazon Nova adotta misure per evitare di completare prompt che potrebbero essere interpretati come una richiesta di informazioni private. Se un utente teme che le sue informazioni private siano state incluse in un completamento di Amazon Nova, deve contattarci [qui](#).

**Sicurezza:** tutti i Amazon Bedrock modelli, incluso Amazon Nova, sono dotati di una sicurezza aziendale che consente ai clienti di creare applicazioni AI generative che supportano standard comuni di sicurezza e conformità dei dati, tra cui GDPR e HIPAA. I clienti possono utilizzare AWS PrivateLink per stabilire una connettività privata tra Amazon Nova personalizzate e reti locali senza esporre il traffico dei clienti a Internet. I dati dei clienti sono sempre crittografati in transito e in archivio e i clienti possono utilizzare le proprie chiavi per crittografare i dati, ad esempio utilizzando AWS Key Management Service. I clienti possono utilizzare AWS Identity and Access Management per controllare in modo sicuro l'accesso alle Amazon Bedrock risorse, tra cui Amazon Nova personalizzato. Inoltre, Amazon Bedrock offre funzionalità complete di monitoraggio e registrazione in grado di supportare i requisiti di governance e audit dei clienti. Ad esempio, Amazon CloudWatch può aiutare a tenere traccia dei parametri di utilizzo necessari a fini di audit e AWS CloudTrail può aiutare a monitorare l'attività delle API e risolvere i problemi poiché Amazon Nova è integrato con altri sistemi. AWS I clienti possono anche scegliere di archiviare i metadati, i prompt e i completamenti nel proprio bucket crittografato Amazon Simple Storage Service (Amazon S3).

**Proprietà intellettuale:** AWS [offre una copertura di indennizzo illimitata sulla proprietà intellettuale \(IP\) per i prodotti dei modelli Amazon Nova generalmente disponibili \(vedi la Sezione 50.10 dei Termini di servizio\)](#). Ciò significa che i clienti sono protetti dalle rivendicazioni di terzi relative alla violazione o all'appropriazione indebita della proprietà intellettuale (incluse le rivendicazioni sul copyright) da parte degli output generati da questi modelli Amazon Nova. Inoltre, la nostra indennità IP standard per l'uso dei Servizi protegge i clienti da rivendicazioni di terzi relative a presunte violazioni della proprietà intellettuale (incluse le rivendicazioni sul copyright) da parte dei Servizi (inclusi i modelli Amazon Nova) e dai dati utilizzati per addestrarli.

# Quote per Amazon Nova

Hai Account AWS delle quote predefinite, precedentemente denominate limiti, per Amazon Bedrock. Per visualizzare le quote di servizio per Amazon Bedrock, effettua una delle seguenti operazioni:

- Segui i passaggi indicati in [Visualizzazione delle quote di servizio](#) e seleziona Amazon Bedrock come servizio.
- Fai riferimento agli [endpoint e alle quote di Amazon Bedrock nel](#). Riferimenti generali di AWS

## Note

Se una quota è contrassegnata come non regolabile tramite Service Quotas, puoi inviare una richiesta tramite il [modulo di aumento del limite](#) per prendere in considerazione un aumento.

Per mantenere le prestazioni del servizio e garantire un uso appropriato di Amazon Bedrock, le quote predefinite assegnate a un account potrebbero essere aggiornate in base a fattori regionali, alla cronologia dei pagamenti, all'utilizzo fraudolento, all'and/or approvazione di una richiesta di aumento delle quote.

## Richiedi un aumento delle quote di Amazon Nova

Puoi richiedere un aumento delle quote per il tuo account seguendo questa procedura:

- [Se una quota è contrassegnata come Sì nella colonna Adjustable negli endpoint Amazon Bedrock e quote in Riferimenti generali di AWS, puoi modificarla seguendo i passaggi riportati nella sezione Richiedere un aumento della quota nella Service Quotas User Guide nella Service Quotas User Guide.](#)
- Le quote di invocazione del modello On-demand negli [endpoint Amazon Bedrock e le quote in Riferimenti generali di AWS non sono modificabili](#) tramite Service Quotas. Contatta il tuo Account AWS manager per farti prendere in considerazione per un aumento.

 Note

A causa dell'enorme domanda, verrà data priorità ai clienti che generano traffico che utilizza la loro assegnazione di quote esistenti. La tua richiesta potrebbe essere rifiutata se non soddisfi questa condizione.

- Puoi inviare una richiesta tramite il [modulo di aumento del limite](#) per candidarti a un aumento anche se una quota è contrassegnata come No nella colonna Regolabile in [Amazon Bedrock endpoints and quotas](#) nella Riferimenti generali di AWS.



# Monitoraggio di Amazon Nova

Il monitoraggio è una parte importante per mantenere l'affidabilità, la disponibilità e le prestazioni di Amazon Nova e delle altre AWS soluzioni. AWS fornisce i seguenti strumenti di monitoraggio per monitorare Amazon Nova, segnalare quando qualcosa non va e intraprendere azioni automatiche quando necessario:

Dato che Amazon Nova è disponibile tramite Amazon Bedrock, segui tutte le linee guida disponibili alla pagina [Monitor the health and performance of Amazon Bedrock](#).

# Sicurezza in Amazon Nova

La sicurezza del cloud AWS è la massima priorità. In qualità di AWS cliente, puoi beneficiare di data center e architetture di rete progettati per soddisfare i requisiti delle organizzazioni più sensibili alla sicurezza.

La sicurezza è una responsabilità condivisa tra te e te. AWS Il [modello di responsabilità condivisa](#) descrive questo aspetto come sicurezza del cloud e sicurezza nel cloud:

- Sicurezza del cloud: AWS è responsabile della protezione dell'infrastruttura che gestisce AWS i servizi in Cloud AWS. AWS fornisce inoltre servizi che è possibile utilizzare in modo sicuro. I revisori esterni testano e verificano regolarmente l'efficacia della nostra sicurezza nell'ambito dei [AWS Programmi di AWS conformità dei Programmi di conformità](#) dei di . Per ulteriori informazioni sui programmi di conformità applicabili ad Amazon Nova, consulta [AWS Services in Scope by Compliance Program AWS](#) .
- Sicurezza nel cloud: la tua responsabilità è determinata dal AWS servizio che utilizzi. Sei responsabile anche di altri fattori, tra cui la sensibilità dei tuoi dati, i requisiti aziendali e le leggi e i regolamenti applicabili.

Dato che Amazon Nova è disponibile tramite Amazon Bedrock, segui tutte le linee guida di sicurezza disponibili alla pagina [Security in Amazon Bedrock](#).

# Crea risorse Amazon Nova con AWS CloudFormation

Quando distribuisce modelli Amazon Nova tramite Amazon Bedrock con CloudFormation, segui tutte le CloudFormation indicazioni riportate nella sezione Create [Amazon Bedrock resources](#) with CloudFormation

Per ulteriori informazioni, inclusi esempi di modelli JSON e YAML per, consulta [YOUR-SERVICE-RESOURCE-TOPNODE-IN-CLOUDFORMATION YOUR-RESOURCE-PLURAL](#), [modifica questo collegamento nel file local-phrases.ent](#) nella Guida per l'utente.AWS CloudFormation

## Scopri di più su CloudFormation

Per ulteriori informazioni CloudFormation, consulta le seguenti risorse:

- [AWS CloudFormation](#)
- [AWS CloudFormation Guida per l'utente](#)
- [Documentazione di riferimento dell'API CloudFormation](#)
- [AWS CloudFormation Guida per l'utente dell'interfaccia a riga di comando](#)

# Cronologia dei documenti per l'Amazon Nova Developer Guide

La tabella seguente descrive le versioni della documentazione per Amazon Nova 2.0.

| Modifica                                             | Descrizione                                                                                                                                                                                                                                                  | Data            |
|------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------|
| <a href="#">Versione iniziale di Amazon Nova 2.0</a> | Versione iniziale della Amazon Nova 2.0 Developer Guide con nuovi modelli: Nova 2 Lite, Amazon Nova Sonic e. Questa guida introduce funzionalità multimodali avanzate, funzionalità di ragionamento e prestazioni migliorate su tutti i livelli del modello. | 2 dicembre 2025 |

Le traduzioni sono generate tramite traduzione automatica. In caso di conflitto tra il contenuto di una traduzione e la versione originale in Inglese, quest'ultima prevarrà.