



Guia do desenvolvedor do Amazon Nova 2

Amazon Nova



Amazon Nova: Guia do desenvolvedor do Amazon Nova 2

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

As marcas comerciais e imagens de marcas da Amazon não podem ser usadas no contexto de nenhum produto ou serviço que não seja da Amazon, nem de qualquer maneira que possa gerar confusão entre os clientes ou que deprecie ou desprestige a Amazon. Todas as outras marcas comerciais que não pertencem à Amazon pertencem a seus respectivos proprietários, que podem ou não ser afiliados, patrocinados pela Amazon ou ter conexão com ela.

Table of Contents

O que é o Amazon Nova 2?	1
Principais conceitos	1
Modelos do Amazon Nova	1
O que você pode criar?	2
Benefícios	3
Como o Amazon Nova funciona	3
Preços	4
Próximas etapas	4
Novidades do Amazon Nova 2	5
Modelos novos	5
Novos recursos e funcionalidades	5
Incorporador Multimodal do Nova	5
Raciocínio e pensamento estendido	5
Ferramentas incorporadas	6
Criação de agentes de IA	6
Compreensão aprimorada de documentos	6
Compreensão aprimorada de vídeos	6
Personalização do modelo	6
Amazon Nova Forge	7
Próximas etapas	7
Introdução	8
Começar a usar o console	8
Explorar o playground de texto	9
Conceitos básicos da API	9
Obter credenciais para conceder acesso programático	11
Anexar permissões do Amazon Bedrock a um usuário ou perfil	13
Gerar uma resposta para um prompt de texto usando um modelo do Amazon Nova	13
Inferência principal	15
Importante: configuração de tempo limite	16
Tópicos principais de inferência	16
Usar a API Converse	17
Estrutura de solicitações	17
Uso de prompts do sistema	18
Parâmetros de inferência	19

Uso do raciocínio	20
Usar a API Invoke	22
Estrutura de solicitações	23
Parâmetros de solicitação	24
Respostas de streaming	24
Streaming com ConverseStream	24
Streaming com InvokeModelWithResponseStream	25
Tipos de evento de streaming	25
Uso de incorporações do Amazon Nova	26
Atributos principais	26
Geração de incorporações	27
Inferência sob demanda	30
Benefícios	31
Uso de inferência sob demanda	31
Preços	31
Cotas e limites	32
Uso dos recursos do Nova	33
Reasoning	33
Compreensão multimodal	34
Tipo de conteúdo compatível por modalidade	34
Compreensão de imagens	35
Compreensão de vídeos	38
Compreensão do documento	40
Conversão de fala em fala	43
Atributos principais	43
Introdução	44
Indicar as importações e a configuração	44
Definir a classe SimpleNovaSonic	45
Inicialize o cliente	46
Gerir eventos	46
Iniciar a sessão	46
Gerir a entrada de áudio	49
Encerrar a sessão	51
Manipulador de resposta	51
Reprodução de áudio	53
Capturar áudio	54

Executar a função principal	55
Exemplos de código	56
Exemplos para começar a usar	56
Casos de uso avançados	57
Workshop prático	58
Prompts de conversa por voz	58
Diretrizes importantes	58
Prompt de sistema de linha de base recomendado para voz	59
Configuração do prompt de fala	59
Configuração do prompt do sistema	60
Concordância de gênero para idiomas com gênero gramatical	61
Cadeia de pensamento para a fala: raciocínio constitucional	62
Uso excessivo de frases sugeridas	63
Principais conceitos	65
Ciclo de vida do evento	65
Sequência de fluxo de eventos	67
Processamento de eventos de entrada com a API bidirecional	67
Processamento de eventos de saída com a API bidirecional	76
Barge-in (Interrupção)	83
Controle da alternância de turnos	84
Entrada intermodal	86
Suporte linguístico e recursos multilíngues	89
Gerenciamento do histórico do chat	90
Configuração de ferramentas	96
Chamada de ferramentas assíncronas	104
Integrações	107
Strands Agents	107
Integrações do framework	110
Sistemas avançados com o Nova	121
Visão geral	121
Pensamento estendido	121
Como funciona o pensamento estendido	121
Opções de configuração	124
Modelos compatíveis	125
Raciocínio estendido com o uso de ferramentas	125
Compreensão de preços e tokens de raciocínio	125

Perguntas frequentes	126
Uso de ferramentas	127
Compreensão do fluxo de trabalho do uso de ferramentas	127
Criar uma ferramenta	128
Chamar uma ferramenta	131
Ferramentas de sistema integradas	134
Criar agentes de IA	137
Crie um agente	137
Invocar um agente	139
Web grounding	142
Como funciona o Web Grounding	142
Como usar o Web Grounding	142
Disponibilidade regional	144
Estrutura de respostas	144
Segurança da ancoragem	145
Tratamento de erros	145
Permissões necessárias para ferramentas integradas	145
Engenharia rápida	147
O que é a engenharia de prompts	147
Conceitos básicos da engenharia de prompts	147
Práticas recomendadas	148
Compreensão dos perfis	148
Criar prompts precisos	149
Dar ênfase às seções do prompt	168
Usar o perfil do sistema	169
Fornecer exemplos (criação de prompts few-shot)	177
Sistemas de chamada de ferramentas	187
Técnicas avançadas de geração de prompts	189
Gerar prompts para entradas multimodais	211
Diretrizes gerais de multimodais	211
Compreensão de documentos e imagens	212
Compreensão de vídeos	38
Código e solução de problemas	225
Biblioteca de códigos	225
Exemplos da API Converse	225
Exemplos da API InvokeModel	245

Solução de problemas	250
Autenticação e configuração	250
Acesso ao modelo negado	251
Problemas de disponibilidade regional	251
Configuração de tempo limite	251
Problemas de respostas das APIs	252
Erros do modo de raciocínio	253
Problemas de uso das ferramentas	254
Referência de APIs e SDKs	258
Esquema de solicitações e respostas	258
Estrutura completa da solicitação	258
Estrutura completa da resposta	263
Referência do SDK	266
Personalização de modelos do Amazon Nova	268
Abordagens de personalização	268
Plataformas de personalização	269
Pré-requisitos gerais	270
Fórmulas do Amazon Nova	271
Obter fórmulas básicas	272
Obtenção de fórmulas do Forge	273
Modelos e algoritmos disponíveis	273
Amazon Nova 2.0 Lite	274
Em tarefas de treinamento do SageMaker	281
Práticas recomendadas para personalização do Amazon Nova	282
Nova Forge SDK	287
Treinamento	293
Monitoramento do progresso em todas as iterações	330
Avaliação	335
Treinamento iterativo	403
No SageMaker HyperPod	403
Requisitos de computação para os modelos do Amazon Nova 2	404
Práticas recomendadas para personalização do Amazon Nova	282
Nova Forge SDK	410
Configuração do cluster no HP	411
Guia de comandos essenciais	411
Configuração e acesso ao Nova Forge	422

Treinamento	423
Avaliação	465
Monitoramento do MLflow	516
Treinamento iterativo	519
Visão geral	519
Como funciona	520
Quando usar o treinamento iterativo	521
Exemplo de fluxo de trabalho: SFT → RFT	522
Monitoramento do progresso em todas as iterações	524
Práticas recomendadas	526
Considerações sobre custos	528
Limitações	529
Solução de problemas	530
Interface do SageMaker	532
Recursos	532
Modelos e instâncias compatíveis	533
Regiões do AWS compatíveis	535
Imagens de contêineres compatíveis	536
Práticas recomendadas	536
Suporte	536
Introdução	537
Referência de API	558
Avaliar modelos	567
Detecção de abusos do Amazon Nova Forge	574
Inferência do Amazon Bedrock.	575
Implementar um modelo personalizado para inferência sob demanda	576
Inferência sob demanda	582
Limitações	583
Nova Forge	585
Pré-requisitos	585
Inscrever-se no Nova Forge	585
Outros pré-requisitos	586
Configuração e acesso ao Nova Forge	586
Obtenção dos documentos do Nova Forge	586
Etapa 1: inscrever-se no Nova Forge	586
Etapa 2. Configurar a infraestrutura do HyperPod	593

Configurações de moderação de conteúdo	593
Pré-treinamento contínuo e treinamento intermediário	594
O que são pontos de verificação intermediários e por que eles são necessários?	594
Quais pontos de verificação estão disponíveis?	595
Qual ponto de verificação usar?	596
Como usar a combinação de dados do Nova 2.0?	597
Dissecação das categorias de combinação de dados	599
Ajuste fino supervisionado	604
Introdução	604
Quando usar o SFT?	604
Quando usar o ajuste eficiente de parâmetros e quando usar o SFT full-rank?	605
Combinação de dados para o SFT	605
Exemplos de configuração YAML	606
Pontos de verificação do modelo	608
Abordagens de treinamento	609
Pré-requisitos antes de começar	610
Uma abordagem sistemática para obter êxito no SFT	610
Sequenciamento de experimentos e combinação de dados	611
Preparar o conjunto de dados para o SFT	612
Métodos de avaliação	612
Práticas recomendadas	282
Preparar a configuração da tarefa de treinamento	614
Configurar o bloco de combinação de dados	616
Como iniciar uma tarefa	622
Como monitorar a tarefa	631
Como avaliar seu modelo após o SFT?	633
Dicas e lições aprendidas	636
Aprendizagem por reforço	636
Traga seu próprio orquestrador para avaliações agênticas em vários turnos	637
Kit de ferramentas de IA responsável	638
Kit de ferramentas de IA responsável	638
Uso responsável	640
Diretrizes	640
Recomendações	641
Cotas	643
Solicitar um aumento das cotas do Amazon Nova	643

Monitoramento	645
Segurança	646
Criar recursos com o CloudFormation	647
Saiba mais sobre o CloudFormation	647
Histórico do documento	648

O que é o Amazon Nova 2?

O Amazon Nova fornece modelos de base multimodais que processam texto, imagens, vídeo, documentos e fala. Com compatibilidade para até 1 milhão de tokens de contexto e recursos avançados de raciocínio, os modelos do Amazon Nova 2 permitem que você crie aplicações sofisticadas de IA que entendem entradas complexas e geram respostas precisas.

Você pode criar chatbots interativos, analisar documentos e vídeos, criar agentes de IA com raciocínio estendido e desenvolver aplicações habilitadas para voz.

Principais conceitos

Antes de saber mais sobre os modelos do Amazon Nova, familiarize-se com os seguintes conceitos principais:

Modelos de base

Sistemas de IA pré-treinados disponíveis em diferentes tamanhos e capacidades que você acessa por meio de uma API.

Inferência

O processo de enviar uma solicitação para um modelo e receber uma resposta gerada.

Reasoning

Capacidade de raciocínio estendido que permite que os modelos resolvam problemas complexos e mostrem sua análise passo a passo antes de fornecer respostas.

Multimodal

A capacidade de processar e entender vários tipos de entrada juntos: texto, imagens, vídeo e documentos em uma única solicitação.

RAG (geração aumentada via recuperação)

Uma técnica que combina respostas do modelo com suas próprias fontes de dados para fornecer respostas contextuais mais precisas.

Modelos do Amazon Nova

O Amazon Nova 2 inclui os seguintes modelos, cada um otimizado para diferentes casos de uso:

Modelo	Modalidades de entrada	Modalidades de saída	Casos de uso
Nova 2 Lite	Texto, imagens, vídeo, documentos	Texto	Aplicações de alto volume que priorizam a velocidade e a eficiência de custos
Nova 2 Sonic	Fala, texto	Fala, texto	Aplicações habilitadas para voz com tempos de resposta rápidos
Incorporador Multimodal do Nova	Texto, imagens, documentos, vídeo, áudio	Incorporações	Pesquisa semântica , sistemas de recomendação e correspondência por similaridade

Todos os modelos são compatíveis com até 1 milhão de tokens de contexto e podem gerar até 65.536 tokens em uma única resposta. Modelos com recursos de raciocínio podem realizar um pensamento estendido para resolver problemas complexos passo a passo.

O que você pode criar?

Confira abaixo exemplos do que você pode criar com o Amazon Nova:

- Assistente inteligente de documentos: processe documentos grandes com até 1 milhão de tokens de contexto para responder a perguntas e extrair insights (com a RAG)
- Aplicações para raciocínio complexo: resolva problemas de várias etapas com um pensamento estendido que mostra a análise passo a passo do modelo (ou com o raciocínio)
- Pipeline de análise de vídeo: extraia insights, gere resumos e identifique momentos-chave no conteúdo de vídeo em grande escala (Nova 2 Lite)
- Agente de IA habilitado para voz: crie agentes de conversação que entendam a entrada de fala e respondam com linguagem natural (Nova 2 Sonic)

Benefícios

O Amazon Nova fornece os seguintes benefícios:

Compreensão multimodal

Processe texto, imagens, vídeos, documentos e voz em uma única solicitação. Os modelos da Amazon Nova compreendem as relações entre diferentes tipos de entrada.

Contexto estendido

A compatibilidade com até 1 milhão de tokens permite que você processe bases de código inteiras, documentos longos ou conversas extensas sem perder o contexto.

Raciocínio avançado

Modelos com recursos de raciocínio detalham problemas complexos e mostram análises passo a passo, melhorando a precisão de tarefas de várias etapas.

Implantação flexível

Acesse modelos por meio do Amazon Bedrock sem infraestrutura para gerenciar, ou personalize modelos por meio de ajuste fino e aprendizado por reforço.

Ferramentas incorporadas

Use a ancoragem na web para acessar informações em tempo real e o interpretador de código para executar o código Python sem integrações externas.

Como o Amazon Nova funciona

Os modelos do Amazon Nova são modelos de base que você acessa por meio do Amazon Bedrock.

O fluxo de trabalho básico é:

1. A aplicação envia uma solicitação ao Amazon Bedrock com seus parâmetros de entrada e configuração.
2. O modelo do Amazon Nova processa sua entrada, aplicando o raciocínio, se configurado.
3. O modelo gera uma resposta e a retorna à sua aplicação.

Você pode aprimorar as respostas usando a RAG para incorporar seus dados, habilitando ferramentas integradas ou personalizando modelos por meio de ajustes finos.

Preços

Os preços do Amazon Nova são baseados nos tokens de entrada e saída processados. Modelos diferentes têm níveis de preços diferentes:

- Nova 2 Lite: otimizado para processamento econômico e de alto volume
- Nova 2 Sonic: preços equilibrados para aplicações habilitadas para voz

Para obter informações atuais sobre preços, consulte [Preços do Amazon Bedrock](#).

Próximas etapas

- Para saber mais sobre os novos recursos do Amazon Nova 2, consulte [Novidades do Amazon Nova 2](#).
- Para começar a usar o Amazon Nova, consulte [Conceitos básicos do Amazon Nova 2](#).
- Para saber mais sobre os principais recursos de inferência, consulte [Inferência principal](#).
- Para personalizar modelos para seu caso de uso, consulte [Personalização de modelos do Amazon Nova no SageMaker AI](#).

Novidades do Amazon Nova 2

O Amazon Nova 2 introduz melhorias significativas nos recursos de compreensão, criatividade e fala. As seções a seguir descrevem os novos recursos e aperfeiçoamentos principais.

Modelos novos

Nova 2 Lite

Modelos aprimorados que oferecem raciocínio avançado compatível com o pensamento estendido, controle de intensidade em três níveis e compreensão multimodal otimizados para fluxos de trabalho agênticos em escala de produção.

Nova 2 Sonic

Um modelo de fala conversacional atualizado com recursos aprimorados de compreensão da fala, processamento de linguagem natural e geração de voz em sete idiomas.

Incorporador Multimodal do Nova

Um modelo de incorporação multimodal que processa entradas de texto, imagem, documento, vídeo e áudio e gera incorporações.

Novos recursos e funcionalidades

Incorporador Multimodal do Nova

O Incorporador Multimodal do Nova é compatível com texto, documentos, imagens, vídeo e áudio por meio de um único modelo, permitindo aplicações de recuperação intermodal. O Incorporador Multimodal do Nova mapeia cada um desses tipos de conteúdo em um espaço semântico unificado, permitindo que você conduza operações vetoriais unimodais, intermodais e multimodais, potencializando aplicações como geração aumentada via recuperação (RAG) agêntica e pesquisa semântica multimodal.

Raciocínio e pensamento estendido

O Nova 2 Lite é compatível com o pensamento estendido, o que permite que os modelos passem mais tempo raciocinando sobre problemas complexos antes de gerar respostas. Esse recurso

melhora a precisão de tarefas de raciocínio em várias etapas, incluindo fluxos de trabalho agênticos com várias ferramentas, matemática avançada, planejamento complexo e geração de código.

Para saber mais, navegue até [Pensamento estendido no Amazon Nova 2](#).

Ferramentas incorporadas

O Amazon Nova 2 inclui ferramentas integradas que ampliam os recursos do modelo sem exigir integrações externas:

- Ancoragem na Web: acessa informações em tempo real da web para fornecer respostas atualizadas e reduzir as alucinações.
- Interpretador de código: executa o código Python para realizar cálculos.

Criação de agentes de IA

Os modelos do Amazon Nova 2 são otimizados para a criação de agentes de IA. Os modelos oferecem melhor uso de ferramentas, melhor raciocínio para tarefas de várias etapas e maior capacidade de manter o contexto em fluxos de trabalho complexos de agentes.

Compreensão aprimorada de documentos

O Nova 2 Lite fornece recursos aprimorados de processamento de documentos com melhor compreensão de layouts complexos de documentos, tabelas, gráficos e documentos de várias páginas. Os modelos extraem informações com mais precisão de PDFs, planilhas e outros formatos de documentos.

Compreensão aprimorada de vídeos

O Nova 2 Lite oferece recursos aprimorados de análise de vídeo, incluindo melhor percepção visual, compreensão temporal, reconhecimento de ações e a capacidade de processar sequências de vídeo mais longas com maior precisão.

Personalização do modelo

O Nova 2 Lite é compatível com o ajuste fino supervisionado (SFT) e o ajuste fino por reforço (RFT) no Amazon Bedrock e no SageMaker AI, permitindo que você adapte o Amazon Nova 2 às suas necessidades empresariais específicas.

Amazon Nova Forge

O Amazon Nova Forge é um serviço inédito que oferece às organizações a maneira mais fácil e econômica de criar seus próprios modelos de fronteira usando o Amazon Nova.

Próximas etapas

- Para saber mais sobre os modelos e recursos do Amazon Nova, consulte [O que é o Amazon Nova 2?](#).
- Para começar a usar o Amazon Nova 2.0, consulte [Conceitos básicos do Amazon Nova 2](#).
- Para conhecer os principais recursos de inferência, consulte [Inferência principal](#).

Conceitos básicos do Amazon Nova 2

Você pode invocar modelos do Amazon Nova 2 por meio dos seguintes métodos:

- Operações da API [InvokeModel](#) ou [Converse](#) do Amazon Bedrock
- [Playgrounds de chat e texto](#) do Amazon Bedrock para o Nova 2 Lite e Nova 2 Sonic

Important

Caso seja iniciante na AWS ou no Amazon Bedrock, você deve primeiro configurar o Amazon Bedrock seguindo as etapas em [Getting started with Amazon Bedrock](#). Como alternativa, você pode experimentar os modelos do Amazon Nova sem entrar no Amazon Bedrock em [nova.amazon.com](#), ou pode começar a criar gratuitamente em [nova.amazon.com/dev](#).

Selecione um tópico para começar a usar o Amazon Nova com esse método.

Conceitos básicos do Amazon Nova no console do Amazon Bedrock

Esta seção descreve como usar os playgrounds no Console da AWS para enviar um prompt de texto para modelos do Amazon Nova 2 e gerar uma resposta de texto ou imagem. Antes de executar os exemplos abaixo, verifique se os seguintes pré-requisitos foram atendidos:

Pré-requisitos

- Você tem uma conta da AWS e permissões para acessar um perfil nessa conta com as permissões necessárias para o Amazon Bedrock. Do contrário, siga as etapas em [Getting started with Amazon Bedrock](#).
- Se você estiver acessando o modelo de uma região dos EUA, deverá usar o endpoint CRIS dos EUA, que envolve a adição do prefixo `us` ao ID do modelo (como `us.amazon.nova-2-lite-v1:0`).
- Se você estiver acessando o modelo de fora dos EUA, poderá usar o endpoint CRIS global (como `global.amazon.nova-2-lite-v1:0`) ou prefixar a região no ID do modelo (como `us/eu/jp`).

Explorar o playground de texto

O seguinte exemplo demonstra como usar o playground de texto:

1. Abra o console do Amazon Bedrock em <https://console.aws.amazon.com/bedrock/>.
2. No painel de navegação à esquerda, escolha Chat/Texto em Playgrounds.
3. Escolha Selecionar modelo e selecione um provedor e um modelo. Neste exemplo, selecione Amazon e depois um modelo do Amazon Nova 2 (como Nova 2 Lite ou Nova 2 Sonic). Em seguida, escolha Aplicar.
4. Selecione um prompt padrão na parte inferior do painel de texto ou insira um prompt no painel de texto, como **Describe the purpose of a "hello world" program in one line.**
5. Para explorar os recursos de compreensão de imagens do Amazon Nova, você pode fazer upload de uma imagem nos formatos JPEG, PNG, GIF ou WEBP com tamanho menor ou igual a 25 MB de seu computador. Depois que a imagem for carregada, você poderá fazer perguntas ao Amazon Nova sobre a imagem.
6. Para explorar os recursos de compreensão de documentos do Amazon Nova, você pode fazer upload de documentos nos formatos CSV, DOC, DOCX, HTML, MD, PDF, TXT, XLS ou XLSX com tamanho menor ou igual a 4,5 MB. Depois que os documentos forem carregados, você poderá fazer perguntas ao Amazon Nova sobre eles.
7. Para explorar os recursos de compreensão de imagem do Amazon Nova, você pode fazer upload de um vídeo nos formatos MKV, MOV ou MP4 com tamanho menor ou igual a 25 MB de seu computador. É possível usar o Amazon S3 para vídeos de até 1 GB. Depois que o vídeo for carregado, você poderá perguntar ao Amazon Nova sobre o vídeo.
8. Escolha Executar para executar a inferência no modelo. O texto gerado aparece na parte inferior do seu prompt no painel de texto.

Conceitos básicos da API da

Antes de começar a usar as APIs, siga esses procedimentos se você for iniciante na AWS ou se precisar instalar a AWS CLI ou um AWS SDK. Se nenhuma dessas opções se aplicar a você, vá para [Obter credenciais para conceder acesso programático](#).

Estou começando na AWS

Se você ainda não tem uma conta da AWS, siga as etapas a seguir para criar uma. Como alternativa, você pode começar a criar gratuitamente com o Amazon Nova em nova.amazon.com/dev.

Para se cadastrar em uma conta da AWS

1. Abra <https://portal.aws.amazon.com/billing/signup>.
2. Siga as instruções online.

Parte do procedimento de inscrição envolve receber uma chamada telefônica ou uma mensagem de texto e inserir um código de verificação pelo teclado do telefone.

Quando você cria uma conta da AWS, um usuário-raiz da conta da AWS é criado. O usuário-raiz tem acesso a todos os serviços e recursos da AWS na conta. Como prática recomendada de segurança, atribua o acesso administrativo a um usuário e use somente o usuário-raiz para executar [tarefas que exigem acesso de usuário-raiz](#).

A AWS envia um e-mail de confirmação depois que o processo de inscrição é concluído. A qualquer momento, é possível exibir as atividades da conta atual e gerenciar sua conta acessando <https://aws.amazon.com/> e selecionando Minha conta.

Proteja seu usuário raiz da conta da AWS

1. Faça login no [Console de gerenciamento da AWS](#) como o proprietário da conta ao escolher a opção Usuário-raiz e inserir o endereço de e-mail da conta da AWS. Na próxima página, insira a senha.

Para obter ajuda ao fazer login usando o usuário-raiz, consulte [Fazer login como usuário-raiz](#) no Guia do usuário de Início de Sessão da AWS.

2. Habilite a autenticação multifator (MFA) para o usuário-raiz.

Para obter instruções, consulte [Habilitar um dispositivo MFA virtual para o usuário-raiz da sua conta da AWS](#) no Guia do usuário do IAM.

Preciso instalar a AWS CLI ou um AWS SDK

Para instalar a AWS CLI, siga as etapas em [Instalar ou atualizar a versão mais recente da AWS CLI](#).

Para instalar um AWS SDK, selecione a guia que corresponde à linguagem de programação que você deseja usar em [Ferramentas para criar na AWS](#).

Os kits de desenvolvimento de software (SDKs) da AWS estão disponíveis para muitas linguagens de programação populares. Cada SDK fornece uma API, exemplos de código e documentação que permitem que os desenvolvedores criem facilmente aplicações em seu idioma de preferência. Os SDKs executam automaticamente tarefas úteis para você, como:

- Assinar de forma criptográfica as solicitações de serviço
- Repetir solicitações
- Lidar com respostas de erro

Obter credenciais para conceder acesso programático

Os usuários precisam de acesso programático se quiserem interagir com a AWS fora do Console de Gerenciamento da AWS. A forma de conceder acesso programático depende do tipo de usuário que está acessando a AWS.

Para conceder acesso programático aos usuários, selecione uma das seguintes opções:

Qual entidade principal precisa de acesso programático?	Para	Por
Usuários do IAM	Limite a duração de credenciais de longo prazo para assinar solicitações programáticas para a AWS, os SDKs da AWS ou as APIs da AWS.	Siga as instruções da interface que deseja utilizar. • Para a AWS CLI, consulte Autenticação usando credenciais de usuário do IAM no Guia do usuário da interface de linha de comandos da AWS. • Para as ferramentas e SDKs da AWS, consulte Autenticação usando as credenciais de longo

Qual entidade principal precisa de acesso programático?	Para	Por
		prazo no Guia de referência de ferramentas e SDKs da AWS. Para as APIs da AWS, consulte Gerenciamento de chaves de acesso de usuários do IAM no Guia do usuário do IAM.
Perfis do IAM	Use credenciais temporárias para assinar solicitações programáticas para a AWS CLI, SDKs da AWS ou APIs da AWS.	Siga as instruções em Usar credenciais temporárias com recursos da AWS no Guia do usuário do IAM.
Usuários gerenciados no Centro de Identidade do IAM	Use credenciais temporárias para assinar solicitações programáticas para a AWS CLI, SDKs da AWS ou APIs da AWS.	Siga as instruções da interface que deseja utilizar. - Para a AWS CLI, consulte Configuração da AWS CLI para usar o Centro de Identidade do IAM no Guia do usuário da interface de linha de comandos da AWS. - Para os SDKs da AWS, as ferramentas e as APIs da AWS, consulte Autenticação do Centro de Identidade do IAM no Guia de referência de ferramentas e SDKs da AWS.

Anexar permissões do Amazon Bedrock a um usuário ou perfil

Depois de configurar as credenciais para acesso programático, você precisa configurar permissões para que um usuário ou um perfil do IAM tenha acesso às ações relacionadas ao Amazon Bedrock. Para configurar essas permissões, faça o seguinte:

1. Na página inicial do Console de Gerenciamento da AWS, selecione o serviço do IAM ou navegue até o console do IAM em <https://console.aws.amazon.com/iam/>.
2. Selecione Usuários ou Perfis e, em seguida, selecione seu usuário ou perfil.
3. Na guia Permissões, escolha Adicionar permissões e depois Adicionar política gerenciada pela AWS. Escolha a política [AmazonBedrockFullAccess](#) gerenciada pela AWS.
4. Para permitir que o usuário ou o perfil assine modelos, escolha Criar política em linha e especifique as seguintes permissões no editor JSON:

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

Gerar uma resposta para um prompt de texto usando um modelo do Amazon Nova

Depois de cumprir todos os pré-requisitos, você pode testar realizando solicitações de invocação de modelo para modelos do Amazon Nova com uma solicitação [Converse](#).

Para instalar a AWS CLI, siga as etapas em [Instalar ou atualizar a versão mais recente da AWS CLI](#). Verifique se você configurou suas credenciais para usar o Boto3 seguindo as etapas em [Obter credenciais para conceder acesso programático](#).

Para gerar uma resposta para um prompt de texto no Nova 2 Lite usando a AWS CLI, execute o seguinte comando em um terminal:

```
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"}}'
```


Inferência principal

Inferência é o processo de enviar uma solicitação para um modelo do Amazon Nova e receber uma resposta gerada. Os modelos do Amazon Nova são compatíveis com a inferência por meio de duas opções de API:

- API Converse ([Converse](#), [ConverseStream](#)): fornece uma interface consistente em diferentes modelos, facilitando a alternância entre modelos ou a criação de aplicações que funcionam com vários modelos. Recomendado para a maioria dos casos de uso.
- API Invoke ([InvokeModel](#), [InvokeModelWithResponseStream](#)): as cargas úteis de solicitação são estruturadas especificamente para o formato nativo de cada modelo. Executa a inferência usando os parâmetros de prompts e inferência fornecidos no corpo da solicitação.

Ambas as APIs são compatíveis com os mesmos recursos principais, incluindo:

- Conversas em vários turnos
- Entradas multimodais (texto, imagens, vídeo, áudio)
- Uso de ferramentas
- Barreiras de proteção
- Respostas de streaming

A estrutura da solicitação é quase idêntica entre as duas APIs, diferindo apenas na forma como os dados em bytes (documentos, imagens, vídeo e áudio) são codificados. Para parâmetros de solicitação de modelo exclusivos dos modelos do Amazon Nova, como `reasoningConfig` e `TopK`, eles são colocados em um objeto `inferenceConfig` adicional em `additionalModelRequestFields`. Estes são os parâmetros de nível superior para `InvokeModel` e `InvokeModelWithResponseStream`.

Note

Analise exemplos de código e a solução de problemas para obter uma lista de exemplos de código com os modelos Nova 2.

Defina `modelId` como um dos seguintes para usar os modelos do Amazon Nova:

Modelo	ID do modelo
Nova 2 Lite	• global.amazon.nova-2-lite-v1:0 • us.amazon.nova-2-lite-v1:0
Nova 2 Sonic	• global.amazon.nova-2-sonic-v1:0 • us.amazon.nova-2-sonic-v1:0
Incorporador Multimodal do Nova	amazon.nova-2-multimodal-embeddings-v1:0

Importante: configuração de tempo limite

Important

As solicitações de inferência do Amazon Nova podem levar até 60 minutos para serem concluídas. Defina as configurações de tempo limite do seu cliente adequadamente: O exemplo a seguir é um código Python. Os usuários podem verificar a documentação da versão do idioma de preferência do SDK nos documentos da API desse SDK.

```
from botocore.config import Config

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

Tópicos principais de inferência

Esta seção discute os seguintes tópicos:

- Usando a API Converse: uma interface consistente que oferece compatibilidade com a maioria dos modelos do Bedrock

- Usando a API Invoke: uma interface exclusiva para modelos Nova e não compatível com outros modelos do Bedrock
- Respostas de streaming: geração de respostas em tempo real
- Uso de incorporações do Amazon Nova: recursos de incorporação de texto
- Inferência sob demanda: modelo de inferência de pagamento conforme o uso

Usar a API Converse

A API Converse fornece uma interface unificada para interagir com os modelos do Amazon Nova. Ela abstrai detalhes específicos do modelo e fornece uma maneira consistente de lidar com conversas em vários turnos, prompts do sistema e respostas de streaming em todos os modelos do Amazon Nova.

Tópicos

- [Estrutura de solicitações](#)
- [Uso de prompts do sistema](#)
- [Parâmetros de inferência](#)
- [Uso do raciocínio](#)

Estrutura de solicitações

- Conversas em vários turnos: mantenha o contexto em várias interações
- Prompts do sistema: instruções do sistema, como personas ou diretrizes de resposta
- Chat de documentos: interaja com e consulte documentos ou coleções de documentos
- Visão: processe e analise imagens e vídeos
- Uso de ferramentas: permita que os modelos usem ferramentas e APIs externas
- Barreiras de proteção: aplique filtros de conteúdo e controles de segurança
- Raciocínio: pensamento estendido para a resolução de problemas complexos

Uma solicitação básica da API Converse inclui o ID do modelo e uma lista de mensagens:

```
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)
```

Uso de prompts do sistema

Prompts do sistema fornecem instruções e contexto ao modelo:

```
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)
```

Parâmetros de inferência

Controle a saída do modelo usando parâmetros de inferência. Os parâmetros de inferência a seguir estão disponíveis.

- **maxTokens** (número inteiro): número máximo de tokens a serem gerados (até 65.000). Se não for especificado, o modelo usa um padrão dinâmico com base no contexto da solicitação.
- **temperature** (flutuação): controla a randomização (0,0 a 1,0, padrão 0,7). Valores mais baixos tornam a saída mais determinística
- **topP** (flutuação): limite de amostragem por núcleo (0 a 1, padrão 0,9). Valores mais baixos tornam a saída mais focada
- **stopSequences** (matriz): sequências de caracteres que interrompem a geração ao serem detectadas

Exemplo:

```
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)
```

Uso do raciocínio

O Nova 2 Lite é compatível com o pensamento estendido para a resolução de problemas complexos. Habilite o raciocínio com `reasoningConfig`.

Por padrão, o raciocínio está desabilitado para otimizar a velocidade e o custo em consultas simples. Quando precisar ir além dessas tarefas simples, você pode habilitar o raciocínio. O Nova 2 permite controlar de forma flexível a profundidade de raciocínio por meio de três níveis de esforço:

Baixo esforço (`maxReasoningEffort: "low"`)

IDEAL PARA: TAREFAS COM MAIOR COMPLEXIDADE QUE EXIGEM PENSAMENTO ESTRUTURADO. Por exemplo, você pode usar para análise de código e sugestões de melhoria em que o modelo precisa considerar cuidadosamente a qualidade do código existente, tarefas de análise que exigem consideração cuidadosa de vários fatores ou cenários de solução de problemas que se beneficiam de uma abordagem metódica. O baixo esforço é ideal para tarefas compostas em que o raciocínio básico melhora a precisão sem exigir um planejamento profundo em várias etapas.

Esforço médio (`maxReasoningEffort: "medium"`)

IDEAL PARA: TAREFAS DE VÁRIAS ETAPAS E FLUXOS DE TRABALHO DE CODIFICAÇÃO. Por exemplo, você pode usar para desenvolvimento e depuração de software em que o modelo precisa entender a estrutura de código existente antes de implementar alterações, geração de código que requer coordenação entre vários arquivos ou componentes, cálculos de várias etapas com interdependências ou tarefas de planejamento com várias restrições. O esforço médio é ideal para fluxos de trabalho agênticos que coordenam várias ferramentas e exigem que o modelo mantenha o contexto em várias operações sequenciais.

Alto esforço (`maxReasoningEffort: "high"`)

IDEAL PARA: RACIOCÍNIO LÓGICO-CIENTÍFICO E RESOLUÇÃO AVANÇADA DE PROBLEMAS. Por exemplo, você pode usar para comprovações e problemas matemáticos avançados que exigem verificação passo a passo rigorosa, análise científica e tarefas de pesquisa que exigem investigação aprofundada, design de sistema complexo com considerações de arquitetura em várias dimensões ou cenários críticos de tomada de decisão com implicações significativas. O alto esforço proporciona a máxima precisão para tarefas que exigem raciocínio sofisticado, avaliação cuidadosa das alternativas e validação completa das conclusões.

Os seguintes exemplos mostram diferentes níveis de esforço de raciocínio:

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"
        }
    }
)
```

Parâmetros de raciocínio:

Confira abaixo os parâmetros de raciocínio

- type: enabled ou disabled (padrão: disabled)
- maxReasoningEffort: low, medium, ou high. É necessário quando o raciocínio está habilitado.

Note

Temperature, topP e topK não podem ser usados com maxReasoningEffort definido como high. Isso causará um erro.

A resposta inclui conteúdo de raciocínio:

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

Note

Com o Amazon Nova 2, o conteúdo de raciocínio é exibido como [REDACTED]. Você ainda é cobrado pelos tokens de raciocínio, pois eles contribuem para melhorar a qualidade da saída. Esse campo foi incluído na estrutura de respostas para preservar a opção de expor o conteúdo de raciocínio no futuro. Estamos trabalhando ativamente com os clientes para determinar a melhor abordagem para desenvolver o processo de raciocínio do modelo.

Usar a API Invoke

A API Invoke fornece acesso direto aos modelos do Amazon Nova com mais capacidade de controlar o formato de solicitações e respostas. Ao contrário da API Converse, que abstrai detalhes específicos do modelo, a API Invoke permite que você trabalhe diretamente com as estruturas nativas de solicitações e respostas do modelo.

 Note

A API Invoke é compatível com os mesmos recursos da API Converse, exceto pela modalidade de entrada de documentos, que é específica da API Converse.

Estrutura de solicitações

Uma solicitação da API Invoke exige o ID do modelo e o corpo da solicitação 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"])
```

Parâmetros de solicitação

A API Invoke é compatível com os seguintes parâmetros principais:

- **messages**: matriz de mensagens de conversação com perfil e conteúdo
- **system**: prompt opcional do sistema para contexto e instruções
- **inferenceConfig**: parâmetros que controlam a saída do modelo (temperature, maxTokens, topP, topK, stopSequences, reasoningConfig)
- **toolConfig**: especificações da ferramenta e escolha da ferramenta para chamada de função

Respostas de streaming

O streaming permite que você receba respostas do modelo de forma incremental à medida que elas são geradas, proporcionando uma experiência de usuário mais interativa. Tanto a API Converse quanto a API Invoke são compatíveis com o streaming.

Streaming com ConverseStream

Use `ConverseStream` para receber respostas como um fluxo de eventos:

```
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 com InvokeModelWithResponseStream

Use `InvokeModelWithResponseStream` para streaming com a 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)
```

Tipos de evento de streaming

As respostas de streaming incluem vários tipos de eventos:

- `messageStart`: indica o início de uma mensagem
- `contentBlockStart`: indica o início de um bloco de conteúdo
- `contentBlockDelta`: contém texto ou dados incrementais
- `contentBlockStop`: indica o fim de um bloco de conteúdo
- `messageStop`: indica o final da mensagem com o motivo da interrupção
- `metadata`: contém informações de uso (contagens de tokens)

Uso de incorporações do Amazon Nova

O Incorporador Multimodal do Amazon Nova é um modelo de incorporação multimodal para aplicações agênticas de RAG e pesquisa semântica. Ele é compatível com texto, documentos, imagens, vídeo e áudio por meio de um único modelo, permitindo a recuperação intermodal. O Incorporador Multimodal do Nova mapeia cada um desses tipos de conteúdo em um espaço semântico unificado, permitindo que os desenvolvedores conduzam operações vetoriais unimodais, intermodais e multimodais.

Quando um conteúdo é processado pelas incorporações do Nova, o modelo converte esse conteúdo em um formato numérico universal, conhecido como vetor. Um vetor é um conjunto de valores numéricos que podem ser usados para várias funcionalidades de pesquisa. Conteúdos semelhantes recebem um vetor mais próximo do que conteúdos menos semelhantes.

Aplicações:

- Recuperação e recomendação de conteúdo semântico: gere incorporações para seu conteúdo e use-as para encontrar itens semelhantes ou fornecer recomendações personalizadas.
- Pesquisa multimodal: combine incorporações de diferentes tipos de conteúdo para habilitar recursos de pesquisa intermodal.
- RAG: gere incorporações a partir de conteúdo multimodal, como documentos com texto e imagens intercalados, para potencializar seu fluxo de trabalho de recuperação para aplicativos GenAI.

Atributos principais

Esses recursos principais se distinguem do Incorporador do Nova:

- Suporte para texto, imagem, imagem de documento, vídeo e áudio em um espaço semântico unificado. A extensão máxima do contexto é de 8 mil tokens ou 30 segundos de vídeo e 30 segundos de áudio.
- APIs síncronas e assíncronas: a API suporta o uso síncrono e assíncrono.
- Segmentação de arquivos grandes: a API assíncrona facilita o trabalho com entradas grandes, fornecendo segmentação criada pela API para texto, vídeo e áudio longos, controlada por parâmetros definidos pelo usuário. O modelo gerará uma única incorporação para cada segmento.
- Vídeo com áudio: processe vídeo com áudio simultaneamente. Especifique se você deseja uma única incorporação representando as duas modalidades ou duas incorporações separadas.

- Propósito da incorporação: otimize suas incorporações dependendo da aplicação downstream pretendida (recuperação/RAG/pesquisa, classificação, clustering).
- Tamanhos das dimensões: 4 tamanhos de dimensão para equilibrar a precisão da incorporação e o custo de armazenamento do vetor: 3072; 1024; 384; 256.
- Métodos de entrada: transmita o conteúdo a ser incorporado especificando um URI do S3 ou em linha como uma codificação base64.

Geração de incorporações

Conclua as ações abaixo para gerar incorporações.

Incorporação síncrona para texto:

```
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))
```

tente:

```
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))
```

Incorporação assíncrona para vídeo:

```
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
#####},
#####},
####},
}
```

tente:

```
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'))
```

Inferência em lote

Com a inferência em lote, é possível enviar várias solicitações e gerar incorporações de forma assíncrona. A inferência em lote ajuda você a processar muitas solicitações de forma eficaz, enviando uma única solicitação e gerando as respostas em um bucket do Amazon S3.

- Depois de definir as entradas do modelo em arquivos que você cria, carregue os arquivos em um bucket do S3.
- Envie uma solicitação de inferência em lote e especifique o bucket do S3.
- Quando o trabalho for concluído, será possível recuperar os arquivos de saída do S3.
- É possível usar a inferência em lote para melhorar a performance da inferência de modelos em grandes conjuntos de dados.

Formatar e carregar os dados de inferência

Você deve adicionar seus dados de inferência em lote a um local do S3 que você escolherá ou especificará ao enviar um trabalho de invocação de modelo. O local do S3 deve conter os seguintes itens:

Pelo menos um arquivo JSONL que define as entradas do modelo. Um JSONL que contém linhas de objetos JSON. Seu arquivo JSONL deve terminar com a extensão .jsonl e estar no seguinte 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"
      }
    }
  }
}
```

Tipos de arquivos de entrada compatíveis

- Formatos de imagem: PNG, JPEG, WEBP, GIF
- Formatos de áudio: MP3, WAV, OGG
- Formato de vídeo: MP4, MOV, MKV, WEBM, FLV, MPEG, MPG, WMV, 3GP

Inferência sob demanda

A inferência sob demanda fornece acesso sem servidor aos modelos do Amazon Nova sem exigir capacidade provisionada. Esse modo é escalado automaticamente para lidar com sua workload e cobranças com base no uso.

Benefícios

A inferência sob demanda apresenta várias vantagens:

- Nenhum planejamento de capacidade: escala automaticamente para atender à demanda
- Pagamento conforme o uso: cobrança somente dos tokens processados
- Disponibilidade instantânea: sem necessidade de provisionamento ou tempo de aquecimento
- Econômica: ideal para workloads variáveis ou imprevisíveis

Uso de inferência sob demanda

A inferência sob demanda é o modo padrão para os modelos do Amazon Nova. Basta especificar o ID do modelo ao fazer chamadas de 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)
```

Preços

A inferência sob demanda é cobrada com base no número de tokens de entrada e saída processados. Para obter detalhes atuais sobre preços, consulte [Preços do Amazon Bedrock](#).

Cotas e limites

A inferência sob demanda tem cotas padrão que variam de acordo com o modelo e a região. Para solicitar aumentos de cota, use o [console do Service Quotas](#).

Uso dos recursos do Amazon Nova 2

Este guia fornece fórmulas baseadas em tarefas e exemplos práticos para ajudar você a integrar os recursos do Nova em suas aplicações de forma rápida e eficaz. Ele foi projetado para desenvolvedores e engenheiros que desejam:

- Integrar modelos Nova em suas aplicações via API
- Entender os requisitos de pré-processamento e as estratégias de otimização
- Implementar fluxos de trabalho de compreensão multimodal

Cada seção fornece:

- Principais informações técnicas sobre formatos compatíveis, limites de tamanho e estimativa de tokens
- Exemplos de códigos simples que demonstram como usar a API tanto com upload direto quanto com o Amazon S3
- Casos de uso que mostram aplicações práticas
- Limitações a considerar ao projetar sua aplicação

Pré-requisitos

Antes de começar, verifique se você tem:

- Uma Conta da AWS com acesso ao Amazon Bedrock
- Permissões do IAM apropriadas para invocar modelos do Bedrock
- AWS SDK instalado (Boto3 para exemplos Python)
- Conhecimento básico dos serviços da AWS, como o Amazon S3 (para manipulação de arquivos grandes)

Recursos de raciocínio

O Amazon Nova 2 Lite é compatível com o pensamento estendido, que está desabilitado por padrão. Quando habilitado, o modelo gera tokens de raciocínio interno que melhoram a qualidade da resposta. No Amazon Nova 2 Lite, o conteúdo do raciocínio é ocultado na saída e exibido como [REDACTED], embora você ainda seja cobrado por esses tokens.

O campo de raciocínio é incluído na estrutura das respostas para preservar a opção de expor esse conteúdo em versões futuras. Para obter mais informações sobre pensamento estendido, consulte [the section called “Pensamento estendido”](#) e [the section called “Biblioteca de códigos”](#).

Compreensão multimodal

O Amazon Nova 2 Lite pode compreender várias modalidades de entrada. Esse modelo é fornecido com recursos visuais que permitem que ele compreenda e analise imagens, documentos, vídeos e fala para inferir e responder a perguntas com base no conteúdo fornecido.

Esta seção descreve as diretrizes para trabalhar com imagens, documentos e vídeos no Amazon Nova, incluindo estratégias de pré-processamento empregadas, exemplos de código e limitações relevantes a serem consideradas.

Tipo de conteúdo compatível por modalidade

As informações a seguir detalham os formatos de arquivo compatíveis com cada tipo de arquivo de mídia e o método de entrada aceito.

Tipo de arquivo de mídia	Formatos de arquivo compatíveis	Método de entrada	Limitações de tamanho	Número de objetos
Imagem	PNG, JPEG, GIF, WebP	Incorporação de dados na solicitação	25 MB	5
	Observação: se você usar um arquivo GIF ou WebP animado, somente o primeiro quadro será usado.	Se você usar a API Converse, codifique dados como bytes. Se você usar a API Invoke, codifique os dados como string Base64.		
		URI do Amazon S3	2 GB no total	1000
Vídeo	MP4, MOV, MKV, WebM,	Incorporação de dados na solicitação	25 MB	1

Tipo de arquivo de mídia	Formatos de arquivo compatíveis	Método de entrada	Limitações de tamanho	Número de objetos
	FLV, MPEG, MPG, WMV, 3GP	Se você usar a API Converse, codifique dados como bytes. Se você usar a API Invoke, codifique os dados como string Base64.		
		URI do Amazon S3	1 GB	1

Tópicos

- [Compreensão de imagens](#)
- [Compreensão de vídeos](#)
- [Compreensão do documento](#)

Compreensão de imagens

A compreensão da imagem refere-se à capacidade do Amazon Nova de processar uma imagem e realizar uma variedade de tarefas de visão computacional, como:

- Execução de detecção de objetos
- Respostas a perguntas sobre imagens por meio do Visual Question Answering (VQA)
- Classificação e resumo de imagens
- Execução da detecção de caixa delimitadora
- Reconhecimento óptico de caracteres (OCR)
- Contagem de objetos

As imagens podem ser incluídas como um prompt transmitido para a API como matrizes de bytes ou por meio do URI do S3.

Informações técnicas importantes

Confira a seguir as principais informações técnicas a serem observadas quando você trabalha com esse recurso.

Dimensionamento e redimensionamento de imagens

O Amazon Nova redimensiona automaticamente as imagens para otimizar a qualidade e o desempenho:

- Determina a taxa de proporção mais próxima (como 1:1, 1:2, 2:3 etc.)
- Redimensiona para que um lado seja ≥ 896 px ou corresponda ao lado mais curto da imagem original, o que for maior
- Mantém a taxa de proporção
- Compatível com a resolução de até 8.000×8.000 px

Coordenadas da caixa delimitadora:

- Útil para tarefas como identificação de elementos em capturas de tela ou ancoragem de imagens
- As coordenadas podem ser redimensionadas para corresponder às dimensões originais da imagem no pós-processamento
- Retorna caixas delimitadoras em uma escala $[0, 1000]$.

Estimativa do token de imagem

O Amazon Nova converte cada imagem em tokens para processamento. O número de tokens depende da resolução e da taxa de proporção da imagem.

Confira a seguir exemplos de contagens aproximadas de tokens com base na resolução da imagem:

Resolução de imagem	Tokens estimados
900 x 450	515
900 x 900	~1.035
1400 x 900	~1.600

Resolução de imagem	Tokens estimados
1800 x 900	~2.060
1300x1300	~2.155

Exemplos de compreensão de imagens

Para obter um exemplo de como incorporar dados de imagem diretamente na solicitação, consulte o exemplo de entrada multimodal usando o ativo incorporado - API Converse (sem streaming) na [Biblioteca de códigos](#).

Para enviar arquivos de imagem grandes ou vários arquivos de imagem, em que a carga útil geral é maior que 25 MB, use o Amazon S3. Para obter um exemplo completo de como usar referências de URI do Amazon S3 para entrada de imagem, consulte o exemplo de entrada multimodal usando o URI do S3 - API Converse (sem streaming) na [Biblioteca de códigos](#).

Note

Ao usar o S3, certifique-se de que o serviço do Amazon Bedrock tenha permissão para acessar o bucket e o objeto.

Principais limitações

A lista a seguir descreve as limitações atuais dos modelos de compreensão de imagens:

- **Compreensão multilíngue de imagens:** os modelos têm uma compreensão limitada de imagens e quadros de vídeo multilíngues e podem ter dificuldades ou alucinações em tarefas simples.
- **Identificação de pessoas:** os modelos do Amazon Nova 2 não são compatíveis com o recurso de identificar ou nomear indivíduos em imagens, documentos ou vídeos.
- **Raciocínio espacial:** os modelos do Amazon Nova 2 têm recursos limitados de raciocínio espacial. Eles podem ter dificuldades com tarefas que exijam localização precisa ou análise de layout.
- **Texto pequeno em imagens e vídeos:** se o texto na imagem ou no vídeo for muito pequeno, considere aumentar o tamanho relativo do texto na imagem recortando a seção relevante e preservando o contexto necessário.

Compreensão de vídeos

A compreensão de vídeo refere-se à capacidade do Amazon Nova de processar entradas de vídeo e realizar uma série de tarefas de compreensão de vídeo, como:

- Análise de quadros-chave e resumo de conteúdo de vídeo
- Respostas a perguntas sobre segmentos de vídeo (Video Question Answering ou Video QA)
- Detecção e rastreamento de objetos em quadros
- Identificação de ações, cenas e eventos
- Execução de segmentação temporal para localizar momentos específicos
- Geração de legendas descritivas ou resumos de sequências de vídeo

Informações técnicas importantes

Confira a seguir as principais informações técnicas a serem observadas quando você trabalha com esse recurso.

Informações sobre o tamanho do vídeo

Os recursos de compreensão de vídeo do Amazon Nova são compatíveis com diversas proporções de tela. Todos os vídeos são redimensionados com distorção (aumentados ou reduzidos, com base na taxa de proporção original) para dimensões de um quadrado de 672 x 672 antes de serem inseridos no modelo.

O modelo utiliza uma estratégia de amostragem dinâmica baseada na duração do vídeo. Para vídeos de 16 minutos ou menos, o Amazon Nova 2 Lite amostra um quadro por segundo (FPS). Para vídeos com mais de 16 minutos de duração, a taxa de amostragem diminui para manter uma amostra consistente de 960 quadros, com a taxa de amostragem de quadros variando de acordo. Essa abordagem foi projetada para fornecer uma compreensão de vídeo mais precisa em nível de cena para vídeos mais curtos em comparação com o conteúdo de vídeos mais longos.

Recomendamos que você mantenha a duração do vídeo em menos de uma hora para movimentação baixa, e menos de 16 minutos para qualquer coisa com maior movimentação.

Não deve haver diferença ao analisar uma versão 4K de um vídeo e uma versão Full HD. Da mesma forma, como a taxa de amostragem é de 1 FPS, um vídeo de 60 FPS deve ter o mesmo desempenho que um vídeo de 30 FPS. Usar uma resolução e FPS acima do necessário não é benéfico devido ao limite de 1 GB no tamanho do vídeo. Isso limitará a duração do vídeo que se

encaixa nesse limite de tamanho. Portanto, é recomendável pré-processar vídeos com duração maior que 1 GB.

Tokens de vídeo

A duração do vídeo é o principal fator que afeta o número de tokens gerados. Para calcular o custo aproximado, multiplique o número estimado de tokens de vídeo pelo preço por token do modelo específico que está sendo utilizado.

A seguinte tabela fornece algumas aproximações de amostragem de quadros e utilização de tokens por duração de vídeo para o Amazon Nova 2 Lite:

Duração do vídeo	Quadros para amostragem	Taxa de amostragem fps	Tokens aproximados
10 segundos	10	1	2.880
30 segundos	30	1	8.640
16 minutos	960	1	276.480
20 minutos	1200	1	345.600
30 minutos	1800	1	518.400
45 minutos	2700	1	777.600

Exemplos de compreensão de vídeos

Para ver um exemplo de como incorporar dados de vídeo diretamente na solicitação, consulte o exemplo de entrada multimodal usando ativo incorporado - API Converse (sem streaming) na [Biblioteca de códigos](#).

Para ver um exemplo de como usar referências do URI do S3 na entrada de vídeo, consulte o exemplo de entrada multimodal usando o URI do S3 - API Converse (sem streaming) na [Biblioteca de códigos](#).

Principais limitações

Confira abaixo as principais limitações dos modelos, em que a precisão e o desempenho deles podem não ser garantidos:

- Sem suporte de áudio: atualmente, os modelos do Amazon Nova são treinados para processar e compreender o conteúdo de vídeo apenas com base nos quadros visuais. As faixas de áudio nos vídeos não são processadas nem analisadas.
- Compreensão multilíngue de imagens: os modelos do Amazon Nova têm uma compreensão limitada de imagens e quadros de vídeo multilíngues. Eles podem ter dificuldades ou apresentar alucinações em tarefas simples.
- Identificação de pessoas: os modelos do Amazon Nova não são compatíveis com a capacidade de identificar ou nomear indivíduos em imagens, documentos ou vídeos. Os modelos não fornecerão nomes ou identidades de pessoas no conteúdo visual.
- Texto pequeno em vídeos: se o texto na imagem ou no vídeo for muito pequeno, considere aumentar o tamanho relativo do texto no vídeo.
- Raciocínio espacial: os modelos do Amazon Nova 2 têm recursos limitados de raciocínio espacial. Eles podem ter dificuldades com tarefas que exijam uma compreensão precisa de posições de objetos, distâncias ou relações espaciais em vídeos.
- Conteúdo impróprio: os modelos do Amazon Nova não processarão imagens impróprias ou explícitas que violem a Política de Uso Aceitável.
- Aplicações de saúde: devido à natureza sensível desses artefatos, embora os modelos do Amazon Nova possam fornecer análises gerais sobre imagens ou vídeos de saúde, não recomendamos seu uso para a interpretação de imagens médicas sensíveis, como exames diagnósticos complexos. A resposta dos modelos do Amazon Nova nunca deve ser considerada um substituto do aconselhamento médico profissional.

Compreensão do documento

A capacidade de compreensão de documentos do Amazon Nova permite que você inclua documentos inteiros (PDFs, arquivos do Word, planilhas etc.) como parte do seu prompt. Isso permite que o modelo analise, resuma, extraia informações ou responda a perguntas sobre o conteúdo do documento.

O Amazon Nova 2 Lite pode interpretar tanto o texto quanto os elementos visuais (como gráficos ou tabelas) nesses documentos. Isso permite casos de uso como resposta a perguntas, resumo e análise de relatórios longos ou documentos digitalizados.

Os principais recursos da compreensão de documentos incluem uma janela de contexto muito grande (1 milhão de tokens) para documentos longos e a capacidade de lidar com vários documentos em uma consulta.

Modalidades e formatos de documentos compatíveis

O Amazon Nova distingue entre dois tipos de entradas de documentos:

- Tipos de documentos baseados em texto, como arquivos DOC, TXT, CSV, HTML ou Markdown, são processados principalmente por seu conteúdo textual. O Amazon Nova compreende e extrai informações do texto nesses documentos.
- Documentos baseados em mídia, como arquivos PDF ou DOCX, podem conter layouts, imagens, tabelas ou gráficos incorporados complexos. Para documentos baseados em mídia, o Amazon Nova emprega a compreensão baseada na visão para interpretar o conteúdo visual, como gráficos, tabelas, diagramas ou capturas de tela, junto com o texto do documento.

Os formatos de arquivo compatíveis incluem tipos de documentos comuns, como:

- Texto simples e arquivos de texto estruturado: CSV, TXT
- Planilhas: XLS, XLSX, HTML, Markdown
- Formatos de imagem padrão (para imagens em documentos): PNG, JPG, GIF, WebP
- Formatos de documentos: DOC, DOCX, PDF
- PDFs que contêm codificações de imagem, como CMYK ou SVG, não são compatíveis.

Limites de tamanho do documento e diretrizes de uso

Restrição	Limite
Número máximo de documentos	Até 5 documentos por solicitação (aplicável tanto ao upload direto quanto ao Amazon S3)
Tamanho do documento baseado em texto	Cada documento de texto deve ser igual ou menor que 4,5 MB
Tamanho do documento baseado em mídia	Para arquivos PDF e DOCX, não há limite de tamanho de arquivo individual. Ao usar o upload direto, o tamanho combinado de todos os documentos de mídia deve ser menor ou igual a 25 MB. Ao usar o Amazon S3, o

Restrição

Limite

tamanho combinado de todos os documentos de mídia deve ser menor ou igual a 2 GB.

Conteúdo em PDF não suportado

PDFs contendo perfis de cores CMYK ou imagens SVG não são compatíveis.

Preços

O Amazon Nova usa preços baseados em tokens: você paga pelos tokens de entrada (tudo o que você envia, incluindo documentos anexados) e pelos tokens de saída (a resposta do modelo).

Estimativa de tokens para PDFs: para planejar, suponha uma página PDF padrão de 8,5 x 11 polegadas com aproximadamente 2.560 tokens de entrada (essa estimativa abrange elementos textuais e visuais em uma página comum).

Exemplos: uso da compreensão de documentos do Nova via API e S3

Para obter um exemplo de como usá-la via API, consulte o exemplo de entrada multimodal usando ativo incorporado - API Converse (sem streaming) na [Biblioteca de códigos](#).

Para obter um exemplo de como usá-la via S3, consulte o exemplo de entrada multimodal usando o URI do S3 - API Converse (sem streaming) na [Biblioteca de códigos](#).

Conversão de fala em fala (Amazon Nova 2 Sonic)

O Amazon Nova 2 Sonic possibilita uma IA conversacional em tempo real com entrada e saída de voz. A seção a seguir aborda recursos avançados para criar assistentes de voz interativos, automação de atendimento ao cliente e aplicações de conversação.

Atributos principais

O Amazon Nova 2 Sonic fornece os seguintes recursos:

- Compreensão de fala em streaming de última geração com API de streaming bidirecional que possibilita conversas em tempo real, com baixa latência e em vários turnos.
- Suporte multilíngue com detecção e troca automáticas de idioma. São oferecidas vozes expressivas, incluindo vozes masculinas e femininas, nos seguintes idiomas:
 - Inglês (EUA, Reino Unido, Índia, Austrália)
 - Francesa
 - Italiana
 - Alemã
 - Espanhola
 - Portuguesa
 - Hindi
- Vozes políglotas que podem falar qualquer um dos idiomas compatíveis para permitir uma experiência de usuário consistente, mesmo quando este muda de idioma na mesma sessão.
- Robustez a ruídos de fundo para cenários de implantação no mundo real.
- Robustez a diferentes sotaques para idiomas compatíveis.
- Experiências de IA conversacional naturais e semelhantes às humanas com riqueza contextual em todos os idiomas compatíveis.
- Resposta de fala adaptativa que ajusta dinamicamente a entrega com base na prosódia da fala de entrada.
- Alternância de turnos inteligente que detecta quando os usuários terminam de falar e quando o assistente deve responder, criando um ritmo natural de diálogo.
- Tratamento amigável das interrupções do usuário sem perder o contexto da conversa.

- Fundamentação de conhecimento com dados empresariais usando geração aumentada via recuperação (RAG).
- Chamada de função e compatibilidade com fluxo de trabalho agêntico para criar aplicações complexas de IA.
- Manipulação assíncrona de ferramentas que executa chamadas de ferramentas enquanto mantém o fluxo da conversa, permitindo que o assistente continue falando enquanto as ferramentas são processadas em segundo plano.
- Suporte de entrada intermodal para entradas de áudio e texto na mesma conversa, possibilitando padrões de interação flexíveis.
- Limite de conexão de oito minutos, com renovação da conexão e padrão de continuação da sessão disponíveis em exemplos de código.

Conceitos básicos da conversão de fala em fala

As seções a seguir fornecem um exemplo e uma explicação passo a passo de como implementar uma aplicação de streaming de áudio simples e em tempo real usando o Amazon Nova 2 Sonic. Essa versão simplificada demonstra a funcionalidade principal necessária para criar uma conversa de áudio com o modelo Amazon Nova 2 Sonic.

Você pode acessar o exemplo a seguir em nosso [repositório de exemplos do Nova para GitHub](#).

Há um limite de conexão de oito minutos, com renovação da conexão e padrão de continuação da conversa disponível no [GitHub](#).

Indicar as importações e a configuração

Esta seção importa as bibliotecas necessárias e define os parâmetros de configuração de áudio:

- `asyncio`: para programação assíncrona
- `base64`: para codificar e decodificar dados de áudio
- `pyaudio`: para captura e reprodução de áudio
- Componentes do SDK do Amazon Bedrock para streaming
- As constantes de áudio definem o formato da captura de áudio (taxa de amostragem de 16 kHz, canal 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
```

Definir a classe **SimpleNovaSonic**

A classe `SimpleNovaSonic` é a classe principal que controla a interação do Amazon Nova Sonic:

- `model_id`: o ID do modelo Amazon Nova Sonic (`amazon.nova-2-sonic-v1:0`)
- `region`: a região da AWS, o padrão é `us-east-1`
- IDs exclusivos para rastreamento de prompts e conteúdo
- Uma fila assíncrona para reprodução de áudio

```
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
```

Inicialize o cliente

Este método configura o cliente do Amazon Bedrock com o seguinte:

- O endpoint apropriado para a região especificada
- Informações de autenticação usando variáveis de ambiente para credenciais da AWS
- O esquema de autenticação do SigV4 para as chamadas de API da 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)
```

Gerir eventos

Este método auxiliar envia eventos JSON para o streaming bidirecional, que é usado para toda a comunicação com o modelo 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)
```

Iniciar a sessão

Este método inicia a sessão e configura os eventos restantes para iniciar o streaming de áudio. Esses eventos precisam ser enviados na mesma ordem.

```
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())

```

Gerir a entrada de áudio

Esses métodos controlam o ciclo de vida da entrada de áudio:

- `start_audio_input`: configura e inicia o fluxo de entrada de áudio
- `send_audio_chunk`: codifica e envia trechos de áudio para o modelo
- `end_audio_input`: fecha adequadamente o fluxo de entrada de áudio

```

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)

```

Encerrar a sessão

Este método fecha adequadamente a sessão ao:

- Enviar um evento `promptEnd`
- Enviar um evento `sessionEnd`
- Fechar o fluxo de entrada

```
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()
```

Manipulador de resposta

Este método processa continuamente as respostas do modelo e faz o seguinte:

- Aguarda a saída do fluxo.

- Analisa a resposta JSON.
- Gerencia a saída de texto imprimindo no console com reconhecimento automático de fala e transcrição.
- Gerencia a saída de áudio decodificando e enfileirando para reprodução.

```
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}")
```

Reprodução de áudio

Este método executará as seguintes tarefas:

- Inicializar um fluxo de entrada PyAudio
- Recupera continuamente dados de áudio da fila
- Reproduz o áudio pelos alto-falantes
- Limpa adequadamente os recursos ao terminar

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

tente:

```
        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()
```

Capturar áudio

Este método executará as seguintes tarefas:

- Inicializa um fluxo de saída PyAudio
- Inicia a sessão de entrada de áudio
- Captura continuamente trechos de áudio do microfone
- Envia cada trecho para o modelo Amazon Nova Sonic
- Limpa adequadamente os recursos ao terminar

```
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()
```

tente:

```
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()
```

Executar a função principal

A função principal orquestra todo o processo executando o seguinte:

- Cria um cliente Amazon Nova 2 Sonic
- Inicia a sessão
- Cria tarefas simultâneas para reprodução e captura de áudio
- Aguarda o usuário pressionar **Enter** para interromper
- Encerra adequadamente a sessão e limpa as tarefas

```
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())
```

Exemplos de código

Esses exemplos de código ajudarão você a começar a usar rapidamente o Amazon Nova 2 Sonic. Você pode acessar a lista completa na página de [exemplos do Amazon Nova Sonic para GitHub](#).

Exemplos para começar a usar

Para exemplos simples projetados para você começar a usar o Amazon Nova 2 Sonic, consulte as seguintes implementações:

- [Implementação básica do Amazon Nova 2 Sonic \(Python\)](#): uma implementação básica que demonstra como os eventos são estruturados na API de streaming bidirecional. Esta versão não é compatível com a funcionalidade de barge-in (interrupção do assistente enquanto ele fala) e não implementa uma comunicação bidirecional verdadeira.
- [Implementação completa do Amazon Nova 2 Sonic \(Python\)](#): a implementação completa com comunicação bidirecional real e compatibilidade com o barge-in. Isso permite conversas mais naturais, em que os usuários podem interromper o assistente enquanto ele fala, semelhante às conversas humanas.

- [Amazon Nova 2 Sonic com o uso de ferramentas \(Python\)](#): uma implementação avançada que amplia os recursos de comunicação bidirecional com exemplos de uso de ferramentas. Esta versão demonstra como o Amazon Nova 2 Sonic pode interagir com ferramentas externas e APIs para fornecer funcionalidade aprimorada.
- [Nova Sonic com entrada mista ou de texto \(Python\)](#): exemplo de implementação para mostrar como o Amazon Nova 2 Sonic pode ter texto como entrada.
- [Implementação Java WebSocket \(Java\)](#): este exemplo implementa uma aplicação de streaming de áudio bidirecional baseado em WebSocket que se integra ao Amazon Nova 2 Sonic para conversação com conversão de fala em fala em tempo real usando Java.
- [Implementação do NodeJS WebSocket \(NodeJS\)](#): este exemplo implementa uma aplicação de streaming de áudio bidirecional baseado em WebSocket que se integra ao Amazon Nova 2 Sonic para conversação com conversão de fala em fala em tempo real usando o NodeJS.
- [Implementação do NodeJS WebSocket \(C#\)](#): este exemplo implementa uma aplicação de streaming de áudio bidirecional baseado em WebSocket que se integra ao Amazon Nova 2 Sonic para conversação com conversão de fala em fala em tempo real usando o .NET.

Casos de uso avançados

Para exemplos avançados que demonstram casos de uso mais complexos, consulte as seguintes implementações:

- [Implementação da Base de Conhecimento para Amazon Bedrock \(NodeJS\)](#): este exemplo demonstra como criar uma aplicação conversacional inteligente integrando o Amazon Nova 2 Sonic com a Base de Conhecimento para Amazon Bedrock usando o NodeJS.
- [Gerenciamento do histórico de chat \(Python\)](#): este exemplo inclui um sistema de registro em log do histórico de chat que captura e preserva todas as interações entre o usuário e o Amazon Nova 2 Sonic usando Python.
- [Cancelamento de reservas de hotel \(NodeJS\)](#): este exemplo demonstra um caso prático de uso de atendimento ao cliente do Amazon Nova 2 Sonic, implementando um sistema de cancelamento de reservas de hotel usando o NodeJS.
- [Integração da Base de Conhecimento para LangChain \(Python\)](#): esta implementação demonstra como integrar os recursos de conversão de fala em fala do Amazon Nova 2 Sonic com uma base de conhecimentos baseada em LangChain para experiências de conversação aprimoradas usando Python.

- [Retomada da conversa \(NodeJS\)](#): este exemplo demonstra como implementar recursos de retomada da conversa com o Amazon Nova 2 Sonic. Usando um cenário de cancelamento de reservas de hotel como contexto, a aplicação mostra como manter o estado da conversa entre as sessões, permitindo que os usuários continuem sem problemas as interações que foram previamente interrompidas, usando o NodeJS.
- [Nova 2 Sonic Speaks First \(NodeJS\)](#): este exemplo demonstra como o Amazon Nova 2 Sonic pode iniciar conversas de forma proativa.
- [Continuação da sessão \(Python\)](#): este exemplo demonstra como habilitar uma duração ilimitada de conversas com o Amazon Nova 2 Sonic implementando transições de sessão fluidas. A aplicação cria e alterna automaticamente para novas sessões em segundo plano, permitindo que as conversas continuem indefinidamente sem interrupção ou perda de contexto.

Workshop prático

Também oferecemos um workshop prático que orienta você na criação de uma aplicação de chat de voz usando o Amazon Nova 2 Sonic com uma interface de streaming bidirecional. Você pode [acessar o workshop](#) e encontrar os [exemplos completos de código](#).

Prompts de conversa por voz

Nova 2 apresenta o Speech Prompts: um recurso de prompts especializado projetado para controlar a formatação de transcrição específica da fala em hindi. Os prompts de fala funcionam junto com o prompt do sistema, mas têm um propósito distinto:

- Prompt do sistema: controla o comportamento, a personalidade e o estilo de resposta do assistente
- Prompt de fala: controla a formatação da transcrição para troca de código em hindi (scripts latino, devanagari ou mistos)

Diretrizes importantes

Os prompts de fala são pré-configuradas e devem ser usados exatamente conforme documentados. Eles foram projetados para necessidades específicas de formatação de transcrição e não devem ser modificados ou personalizados, pois as alterações podem causar um comportamento inesperado.

Quando usar os prompts de fala:

- Você precisa controlar a saída do script para troca de código em hindi (latino/devanagari/misto)

Quando NÃO usar prompts de fala:

- Para instruções gerais ou comportamento do assistente (use o prompt do sistema)
- Se você não estiver trabalhando com a formatação de transcrição em hindi
- Se a necessidade específica de formatação não se aplicar ao seu caso de uso

Prática recomendada: inclua apenas um prompt de fala se você precisar especificamente de formatação de transcrição em hindi. Todas as outras instruções, incluindo preferências de idioma, estilo de resposta, verbosidade e raciocínio, devem ser enviadas no prompt do sistema.

Importante: os prompts de fala devem ser enviados após o prompt do sistema para o modelo.

Prompt de sistema de linha de base recomendado para voz

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.

Configuração do prompt de fala

Troca de código

Observação: atualmente, este recurso se aplica apenas ao idioma hindi.

Escolha um dos seguintes prompts com base no script de saída desejado:

Para saída no script latino (hindi romanizado):

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

Para saída no script devanagari:

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

Para saída no script misto (troca de código natural):

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

Configuração do prompt do sistema

Controle da verbosidade da resposta

Respostas concisas e conversacionais:

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.

Respostas detalhadas e completas:

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.

Espelhamento de idioma

O Nova pode reconhecer e responder no idioma que o usuário fala. Use este prompt para manter a consistência do idioma:

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.

Concordância de gênero para idiomas com gênero gramatical

Alguns idiomas requerem a concordância de gênero em verbos, adjetivos ou pronomes quando o assistente se descreve. Para esses idiomas, especifique o gênero do assistente no prompt do sistema para corresponder à voz selecionada.

Idiomas afetados: hindi, português, francês, italiano, espanhol, russo, polonês

Quando a concordância de gênero é importante:

- Hindi: sempre necessário; os verbos são conjugados com base no gênero do locutor em primeira pessoa
- Português/francês: necessário ao usar adjetivos ou participípios passados (como “I am tired”: “Estou cansada/cansado”)
- Italiano/espanhol: necessário ao usar adjetivos para descrever a si mesmo (como “I am happy”: “Sono contenta/contento”)

Implementação:

Inclua o identificador de gênero apropriado no início do prompt do sistema com base na sua seleção de voz:

Para vozes femininas (kiara, carolina, ambre, beatrice, lupe, tiffany):

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

Para vozes masculinas (arjun, leo, florian, lorenzo, carlos, matthew):

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

Examples:

Hindi com voz feminina (kiara):

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

Resultado: मैं अच्छी हूँ (main achchhi hoon) vs मैं अच्छा हूँ (main achchha hoon)

Italiano com voz masculina (lorenzo):

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

Resultado: “Sono contento” vs “Sono contenta”

Cadeia de pensamento para a fala: raciocínio constitucional

Use esse prompt quando quiser que o modelo mostre seu raciocínio para problemas complexos:

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.

Observação: caso não queira que o modelo realize o raciocínio para cada solicitação, você pode adicionar alguns exemplos de demonstração ao prompt (veja os exemplos abaixo).

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 excessivo de frases sugeridas

O Nova Sonic 2 é mais sensível às sugestões de frases do que o Sonic 1. Esse aumento de sensibilidade não é necessariamente bom ou ruim, depende do seu caso de uso. Se você quiser uma linguagem consistente e previsível, isso pode ser benéfico. No entanto, se você quiser uma variação mais natural, listas de frases explícitas podem levar ao uso excessivo.

Se você incluir prompts com listas explícitas de frases, o modelo os usará com muita frequência:

Exemplo 1 - Frases de ênfase:

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."

Exemplo 2 - Preenchimentos conversacionais:

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.

Recomendação:

- Se você quiser uma linguagem consistente: listas de frases explícitas funcionam bem no Sonic 2 para criar respostas previsíveis e adequadas à marca.
- Se você quiser variações naturais: evite fornecer listas explícitas de frases. Em vez disso, use orientações gerais, como “soe natural e conversacional”, ou forneça um único exemplo de referência.

Melhor abordagem: use exemplos únicos de referência:

Em vez de listar frases, forneça de 1 a 2 exemplos que demonstrem o tom e o estilo desejados:

Tom natural e útil

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 direto

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.

Profissional com 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?

Técnico, mas acessível

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.


Essa abordagem mostra ao modelo o comportamento desejado sem acionar padrões repetitivos de frases, mantendo o controle sobre o tom e o estilo.

Principais conceitos

O Amazon Nova 2 Sonic usa uma arquitetura de streaming bidirecional com eventos estruturados para IA conversacional em tempo real. Compreender esses conceitos fundamentais é essencial para criar aplicações eficazes de vozes.

Ciclo de vida do evento

O seguinte diagrama ilustra o ciclo de vida completo do evento de streaming bidirecional:



O ciclo de vida do evento de streaming bidirecional segue um padrão estruturado desde a inicialização da sessão até a conclusão da conversa. Cada conversa envolve eventos de entrada (da sua aplicação) e eventos de saída (do Amazon Nova 2 Sonic) que trabalham juntos para criar interações de voz naturais.

Sequência de fluxo de eventos

Uma conversa típica segue esta sequência de eventos:

1. Início da sessão: inicializa a sessão de conversação
2. Prompt do sistema: envia instruções do sistema
3. Histórico do bate-papo (opcional): fornece o contexto da conversa
4. Segmentos de áudio: transmite a entrada de áudio do usuário por streaming
5. Início da conclusão: a IA inicia o processamento
6. Transcrições de ASR (USER): transcrição da fala do usuário
7. Uso da ferramenta (opcional): a IA solicita a execução da ferramenta
8. Manuseio de ferramentas (opcional): processa e devolve resultados da ferramenta
9. Transcrição (ASSISTANT) - SPECULATIVE: resposta preliminar da IA
10. Segmentos de áudio: transmite a saída de áudio da IA por streaming
11. Transcrição (ASSISTANT) - FINAL: transcrição final da resposta da IA
12. Áudio final do conteúdo: marca o fim do conteúdo de áudio
13. Término do prompt: indica a conclusão do processamento do prompt
14. Término da sessão: conclui a conversa

Processamento de eventos de entrada com a API bidirecional

A API de streaming bidirecional usa uma arquitetura orientada por eventos com eventos estruturados de entrada e saída. Compreender a ordem correta dos eventos é crucial para implementar aplicações de conversação bem-sucedidas e manter o estado adequado da conversa durante as interações.

Visão geral

A conversa do Nova Sonic segue uma sequência estruturada de eventos. Você começa enviando um evento `sessionStart` que contém os parâmetros de configuração de inferência, como temperatura

e limites de token. Em seguida, você envia `promptStart` para definir o formato de saída de áudio e as configurações de ferramentas, atribuindo um identificador `promptName` exclusivo que deve ser incluído em todos os eventos subsequentes.

Para cada tipo de interação (prompt do sistema, áudio etc.), você segue um padrão de três partes: use `contentStart` para definir o tipo de conteúdo e o perfil do conteúdo (SYSTEM, USER, ASSISTANT, TOOL, SYSTEM_SPEECH), depois forneça o evento de conteúdo real e finalize com `contentEnd` para concluir o segmento. O evento `contentStart` especifica se você está enviando resultados de ferramentas, transmitindo áudio ou se é um prompt do sistema. O evento `contentStart` inclui um identificador `contentName` exclusivo.

Histórico da conversa

Um histórico de conversa pode ser incluído apenas uma vez, após o prompt do sistema e antes do início do streaming de áudio. Ele segue o mesmo padrão `contentStart/textInput/contentEnd`. Os perfis USER e ASSISTANT devem ser definidos no evento `contentStart` para cada mensagem histórica. Isso fornece um contexto essencial para a conversa atual, mas deve ser concluído antes que qualquer nova entrada do usuário comece.

Streaming de áudio

O streaming de áudio opera com amostragem contínua de microfone. Depois de enviar um `contentStart` inicial, os quadros de áudio (aproximadamente 32 ms cada) são capturados diretamente do microfone e enviados imediatamente como eventos `audioInput` usando o mesmo `contentName`. Essas amostras de áudio devem ser transmitidas em tempo real à medida que são capturadas, mantendo a cadência natural de amostragem do microfone durante toda a conversa. Todos os quadros de áudio compartilham um único contêiner de conteúdo até que a conversa termine e seja explicitamente concluída.


Conclusão da sessão

Depois que a conversa terminar ou precisar ser encerrada, é essencial fechar adequadamente todos os streamings abertos e encerrar a sessão na sequência correta. Para encerrar adequadamente uma sessão e evitar vazamentos de recursos, você deve seguir uma sequência de fechamento específica:

- Feche todos os streamings de áudio abertos com o evento `contentEnd`.
- Envie um evento `promptEnd` que faça referência ao `promptName` original.
- Envie o evento `sessionEnd`.

Ignorar qualquer um desses eventos de encerramento pode resultar em conversas incompletas ou em recursos órfãos.

Esses identificadores criam uma estrutura hierárquica: o `promptName` une todos os eventos da conversa, enquanto cada `contentName` marca os limites de blocos de conteúdo específicos. Essa hierarquia garante que o modelo mantenha o contexto adequado durante toda a interação.



Fluxo de eventos de entrada

A estrutura do fluxo de eventos de entrada é fornecida nesta seção.

1. RequestStartEvent (Início da sessão)

O evento de início da sessão inicializa a conversa com a configuração de inferência e as configurações de detecção de turnos.

Configuração da inferência:

- `maxTokens`: número máximo de tokens a serem gerados na resposta
- `topP`: parâmetro de amostragem de núcleo (0,0 a 1,0) para controlar a randomização
- `temperature`: controla a randomização na geração (0,0 a 1,0)

Configuração de detecção de turnos: o parâmetro `endpointingSensitivity` controla a rapidez com que o Nova Sonic detecta quando um usuário termina de falar:

- **HIGH**: detecta pausas rapidamente, permitindo respostas mais rápidas, mas pode interromper quem fala mais devagar
- **MEDIUM**: sensibilidade balanceada para a maioria dos cenários de conversação (padrão recomendado)
- **LOW**: espera mais antes de detectar o final da fala, melhor para falantes atenciosos ou hesitantes

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

Exemplo:

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


2. PromptStartEvent

O evento de início do prompt define a configuração da conversa, incluindo os formatos de saída, a seleção de voz e as ferramentas disponíveis.

Para obter uma lista de IDs de voz disponíveis, consulte [Suporte a idiomas e recursos multilíngues](#)

```
{
  "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

Texto

O evento de início do conteúdo de texto é usado para prompts do sistema, histórico de conversas e entrada de texto intermodal.

Parâmetro interativo:

- `true`: habilita a entrada intermodal, possibilitando mensagens de texto durante uma sessão de voz ativa
- `false`: entrada de texto padrão para prompts do sistema e histórico de conversas

Tipos de perfil:

- `SYSTEM`: instruções e prompts do sistema
- `USER`: mensagens do usuário no histórico de conversas ou na entrada intermodal
- `ASSISTANT`: respostas do assistente no histórico de conversas
- `SYSTEM_SPEECH`: controla a formatação da transcrição para troca de código em hindi (scripts latino/devanagari/mistos)

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

Exemplo - Prompt do sistema:

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

Exemplo - Entrada intermodal:

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

Áudio

```
{
  "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"
        }
    }
}

```

Ferramenta

```

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

```

4. TextInputContent

```

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

```

```
}
```

5. AudioInputContent

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

6. ToolResultContentEvent

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

7. InputContentEndEvent

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

8. PromptEndEvent

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

```
    }  
  }  
}
```

9. RequestEndEvent

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

Processamento de eventos de saída com a API bidirecional

Quando o modelo Amazon Nova Sonic responde, ele segue uma sequência estruturada de eventos. O fluxo começa com um evento `completionStart` que contém identificadores exclusivos, como `sessionId`, `promptName` e `completionId`. Esses identificadores são consistentes em todo o ciclo de resposta e unem todos os eventos de resposta subsequentes.

Visão geral

Cada tipo de resposta segue um padrão consistente de três partes: `contentStart` define o tipo e o formato do conteúdo, o evento real do conteúdo e `contentEnd` conclui esse segmento. A resposta normalmente inclui vários blocos de conteúdo em sequência: transcrição do reconhecimento automático de fala (ASR) (o que o usuário disse), uso opcional de ferramentas (quando informações externas são necessárias), resposta de texto (o que o modelo planeja dizer) e resposta de áudio (a saída falada).

Tipos de conteúdo de resposta

Transcrição de ASR

A transcrição do ASR aparece primeiro, fornecendo a compreensão do modelo sobre a fala do usuário com `role: "USER"` e `"additionalModelFields": "{ \"generationStage\": \"FINAL\" }"` no `contentStart`.

Uso de ferramentas

Quando o modelo precisa de dados externos, ele envia eventos relacionados à ferramenta com nomes e parâmetros específicos da ferramenta.

Resposta de texto

A resposta de texto fornece uma prévia do discurso planejado com `role: "ASSISTANT"` e `"additionalModelFields": "{\\"generationStage\\":\\"SPECULATIVE\\"}"`.

Resposta de áudio

A resposta de áudio então fornece trechos de fala codificados no Base64 que compartilham o mesmo `contentId` em todo o streaming.

Compatibilidade com o barge-in

Durante a geração de áudio, o Amazon Nova Sonic é compatível com o fluxo natural de conversação por meio de seu recurso de barge-in. Quando um usuário interrompe o Amazon Nova Sonic enquanto ele está falando, o Nova Sonic imediatamente para de gerar fala, muda para o modo de escuta e envia uma notificação de conteúdo indicando que a interrupção ocorreu. Como o Nova Sonic opera mais rápido do que em tempo real, o áudio pode já ter sido entregue, mas ainda não foi reproduzido. A notificação de interrupção permite que a aplicação cliente limpe sua fila de áudios e interrompa a reprodução imediatamente, criando uma experiência conversacional responsiva.

Transcrição final

Depois que a geração de áudio é concluída (ou interrompida via barge-in), o Amazon Nova Sonic fornece uma resposta de texto adicional que contém uma transcrição em nível de frase do que foi realmente falado. Essa resposta de texto inclui um evento `contentStart` com `role: "ASSISTANT"` e `"additionalModelFields": "{\\"generationStage\\":\\"FINAL\\"}"`.

Monitoramento de uso


Durante todo o tratamento da resposta, eventos `usageEvent` são enviados para rastrear o consumo de tokens. Esses eventos contêm métricas detalhadas para tokens de entrada e de saída (tanto de fala quanto de texto) e seus totais acumulados. Cada `usageEvent` mantém o mesmo `sessionId`, `promptName` e `completionId` que outros eventos no fluxo da conversa. A seção de detalhes fornece as alterações incrementais (delta) e os totais acumulados do uso de tokens, permitindo o monitoramento preciso do uso durante a conversa.

Conclusão

O modelo envia um evento `completionEnd` com os identificadores originais e um `stopReason` que indica como a conversa terminou. Essa hierarquia de eventos garante que a aplicação possa rastrear

quais partes da resposta estão associadas e processá-las adequadamente, mantendo o contexto em vários turnos.

O fluxo de eventos de saída começa entrando na fase de geração de resposta. Ele começa com o reconhecimento automático de fala, seleciona uma ferramenta para uso, transcreve a fala, gera áudio, finaliza a transcrição e encerra a sessão.



Fluxo de eventos de saída

A estrutura do fluxo de eventos de saída é fornecida nesta seção.

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": "TOOL",
    "role": "TOOL",
    "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": "TOOL_USE",  
    "type": "TOOL"  
  }  
}
```

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 (Interrupção)

O barge-in permite que os usuários interrompam o assistente de IA enquanto ele fala, assim como em conversas humanas naturais. Em vez de esperar que o assistente termine, os usuários podem intervir com novas informações, corrigir ou esclarecer sua declaração anterior, redirecionar a conversa para um tópico diferente ou simplesmente interromper o assistente quando já tiverem ouvido o suficiente. Isso cria uma experiência de conversação mais natural e responsiva.

O seguinte diagrama ilustra o fluxo completo de conversação com o barge-in:



Como o Amazon Nova 2 Sonic lida com o barge-in

O Amazon Nova 2 Sonic foi projetado para lidar com interrupções com elegância. Quando o usuário começa a falar durante uma resposta, o sistema imediatamente para de gerar a resposta atual, mantém o contexto conversacional completo, envia um sinal de interrupção ao cliente e começa a processar a nova entrada do usuário.

Preservação do contexto: mesmo quando interrompido, o Nova Sonic lembra o que foi dito antes da interrupção, o tópico que está sendo discutido, o histórico da conversa e qualquer contexto relevante dos turnos anteriores. Isso garante que a conversa permaneça coerente e natural.

Requisitos de implementação do lado do cliente

Enquanto o Amazon Nova 2 Sonic lida com o barge-in no lado do servidor, você precisa implementar a lógica do lado do cliente para uma experiência completa.

O desafio da fila de áudio: a geração de áudio é mais rápida do que a velocidade de reprodução. Isso significa que:

- O Nova Sonic gera segmentos de áudio rapidamente
- Seu cliente recebe e enfileira esses segmentos
- O cliente os reproduz na velocidade normal de fala
- Quando ocorre um barge-in, já há um áudio na fila para reprodução

Lógica necessária do lado do cliente: a aplicação deve lidar com quatro etapas principais:

1. Detectar o sinal de interrupção: identifique o evento de interrupção do Nova Sonic e reaja imediatamente ao recebê-lo.
2. Interromper a reprodução atual: pause o áudio em execução e interrompa qualquer áudio que esteja no meio da reprodução.
3. Limpar a fila de áudio: remova todos os segmentos de áudio em fila e descarte qualquer áudio em buffer da resposta interrompida.
4. Iniciar novo áudio: comece a reproduzir o áudio recém-recebido e retome o fluxo normal de reprodução.

Controle da alternância de turnos

A alternância de turnos é um aspecto fundamental de uma conversa natural. O Amazon Nova 2 Sonic oferece um controle refinado sobre o momento em que a IA assume o turno da fala por meio do parâmetro `turnDetectionConfiguration`. Isso permite que você otimize o fluxo de conversas para diferentes casos de uso, equilibrando a capacidade de resposta com a precisão. O parâmetro `endpointingSensitivity` controla a rapidez com que o Amazon Nova 2 Sonic detecta o final do turno de um usuário e começa a responder. Essa configuração afeta tanto a latência das respostas quanto a probabilidade de interromper os usuários que ainda estão falando.

Configuration da API

Configure a sensibilidade de detecção de turnos no evento `sessionStart`:

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

Níveis de sensibilidade

O parâmetro `endpointingSensitivity` aceita três valores: `HIGH`, `MEDIUM` e `LOW`. Cada nível equilibra a velocidade de resposta com o risco de interromper usuários que ainda estão falando.

HIGH (ALTO)

Tempo de resposta mais rápido, otimizado para latência. O Nova Sonic responde o mais rápido possível após detectar o final da fala. Duração da pausa: 1,5 segundo. Ideal para perguntas e respostas rápidas, aplicações de comando e controle e interações sensíveis ao tempo.

MÉDIO

Abordagem equilibrada com tempo de resposta moderado. Reduz os falsos positivos enquanto mantém a capacidade de resposta. Duração da pausa: 1,75 segundo. Ideal para conversas gerais, atendimento ao cliente com consultas complexas e discussões em vários turnos.

BAIXO

Tempo de resposta mais lento com o máximo de paciência. O Nova Sonic espera mais tempo antes de responder, minimizando as interrupções dos usuários que param enquanto pensam. Duração da pausa: 2 segundos. Ideal para conversas profundas, usuários idosos ou com deficiência de fala e resolução de problemas complexos.

Referência da duração da pausa

Nível de sensibilidade	Duração da pausa (segundos)
Alto (rápido)	1.5
Médio	1.75
Baixo (lento)	~2,0

Entrada intermodal

O Amazon Nova 2 Sonic agora é compatível com entrada intermodal, permitindo que você envie mensagens de texto além da entrada de voz durante uma sessão de conversação. Embora a fala continue sendo o principal modo de interação, a entrada de texto oferece flexibilidade para cenários em que a digitação é mais conveniente ou apropriada.

Streaming contínuo necessário: a entrada intermodal requer uma sessão de streaming ativo para funcionar corretamente. A sessão deve manter o streaming contínuo como uma sessão de voz normal, do contrário, os tempos limite padrão da sessão serão aplicados e a conexão será encerrada.

Os níveis de sensibilidade na entrada de texto intermodal são úteis para cenários como:

- Integração de aplicações do lado do cliente (web e dispositivo móvel): permite que os usuários interajam com a aplicação usando texto e voz, oferecendo experiências multimodais integradas.
- Caso de uso do “model-start-first”: uma mensagem de texto pode ser enviada imediatamente após o início da sessão para fazer com que o modelo comece a falar.
- Orientando o modelo durante a chamada assíncrona da ferramenta: quando um evento `toolUse` é acionado e o sistema começa a processar as chamadas da ferramenta, o cliente pode enviar uma mensagem de texto ao Sonic para fornecer uma resposta natural enquanto espera, como: “Espere um segundo enquanto eu processo suas informações. Enquanto isso, posso ajudar com mais alguma coisa?”.
- Integração de telefonia DTMF: o cliente usa o teclado do telefone para inserir informações confidenciais (como números de cartão de crédito). Observação: o Amazon Nova Sonic não processa tons DTMF de forma nativa. Para ser compatível com a entrada DTMF, seu sistema deve detectar os tons, convertê-los em texto (como “1234”) e enviar para o Nova 2 Sonic.

Como funciona

A entrada intermodal usa uma sequência de três eventos semelhante à entrada de áudio:

1. Evento de início de conteúdo: sinaliza o início da entrada de texto
2. Evento de entrada de texto: contém a mensagem de texto real
3. Evento de fim de conteúdo: sinaliza a conclusão da entrada de texto

Todos os três eventos devem usar o mesmo `promptName` e `contentName` para manter a sequência. Um novo UUID deverá ser gerado para `contentName` toda vez que você enviar uma entrada de texto para garantir o rastreamento adequado da conversa em vários turnos.

Estrutura de eventos

1. Evento de início de conteúdo

Inicia a sequência de entrada de texto com detalhes de configuração:

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

Principais parâmetros:

- `promptName`: o nome do seu prompt de conversa (consistente em toda a sessão)
- `contentName`: um identificador único para essa entrada de texto (gere um novo UUID para cada mensagem)
- `role`: defina como "USER" para indicar a entrada do usuário
- `type`: defina como "TEXT" para entrada de texto

- `interactive`: defina como `true` para habilitar o modo interativo
- `mediaType`: defina como `"text/plain"` para conteúdo de texto simples

2. Evento de entrada de texto

Contém o conteúdo real da mensagem de texto:

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

Principais parâmetros:

- `promptName`: deve corresponder ao valor do evento de início de conteúdo
- `contentName`: deve corresponder ao valor do evento de início de conteúdo
- `role`: sua string de mensagem de texto

3. Evento de fim do conteúdo

Sinaliza a conclusão da entrada de texto:

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

Principais parâmetros:

- `promptName`: deve corresponder ao valor de eventos anteriores

- `contentName`: deve corresponder ao valor de eventos anteriores

Suporte linguístico e recursos multilíngues

O Amazon Nova 2 Sonic fornece uma seleção diversificada de vozes em vários idiomas, permitindo que você crie aplicações de IA conversacional que pareçam naturais e culturalmente apropriados para seus usuários. Cada idioma oferece opções de vozes feminina e masculina.

A tabela a seguir lista todas as vozes disponíveis e as respectivas localidades de idioma:

Linguagem	Locale	ID de voz feminina	ID de voz masculina
Inglês (EUA)	en-US	tiffany	matthew
Inglês (Reino Unido)	en-GB	amy	-
Inglês (Austrália)	en-AU	olivia	-
Inglês (indiano)	en-IN	kiara	arjun
Francesa	fr-FR	ambre	florian
Italiana	it-IT	beatriz	lorenzo
Alemã	de-DE	tina	lennart
Espanhol (EUA)	es-US	lupe	carlos
Portuguesa	pt-BR	carolina	leo
Hindi	hi-IN	kiara	arjun

Estrutura de eventos usando vozes em sua aplicação

Você pode especificar o ID de voz em `audioOutputConfiguration` ao iniciar um prompt no evento `promptStart`:

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

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

Suporte multilíngue

O Amazon Nova 2 Sonic fornece recursos multilíngues avançados que permitem conversas naturais em vários idiomas. O serviço é compatível com vozes políglotas (que falam vários idiomas) e troca de código (mistura de idiomas na mesma frase), permitindo que você crie aplicações de conversação verdadeiramente globais.

TIFFANY (en-US, feminino) e MATTHEW (en-US, masculino) são vozes políglotas exclusivas que podem falar todos os idiomas compatíveis:

1. Inglês
2. Francesa
3. Italiana
4. Alemã
5. Espanhola
6. Portuguesa
7. Hindi

Isso torna Tiffany e Matthew ideais para aplicações que precisam alternar entre vários idiomas de forma fluida.

Gerenciamento do histórico do chat

As respostas do Amazon Nova 2 Sonic incluem transcrições de ASR (reconhecimento automático de voz) para vozes de usuários e assistentes. Armazenar o histórico do chat é uma prática


recomendada, não apenas para fins de registro em log, mas também para retomar as sessões quando a conexão é fechada inesperadamente. Isso possibilita o reenvio de contexto pelo cliente ao Nova Sonic, permitindo a continuidade do diálogo de forma fluida.

Consulte os seguintes recursos para obter mais informações sobre o gerenciamento de histórico do chat:

1. [Registro em log do histórico do chat](#)
2. [Retomada das conversas](#)

Envio do histórico do chat

Um histórico de conversa pode ser incluído apenas uma vez, após o prompt de sistema/fala e antes do início do streaming de áudio. O histórico geral do chat não pode ser maior que 40 KB. O seguinte diagrama mostra quando o histórico do chat é transmitido durante o ciclo de vida do evento:



Cada mensagem do histórico requer três eventos: `contentStart`, `textInput` e `contentEnd`.

Esquema do evento por mensagem:

- `contentStart`: define o perfil e a configuração da mensagem

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

- `textInput`: contém o conteúdo real da mensagem. Um `textInput` não pode ser maior que 1 KB. Em caso afirmativo, divida em vários `textInputs` no mesmo bloco de conteúdo. Se a conversa exceder 40 K, reduza o histórico total do chat.

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

- `contentEnd`: marca o fim da mensagem

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

```
}  
}
```

Repita esses três eventos para cada mensagem em seu histórico do chat, alternando entre os perfis de USER e ASSISTANT.

Considerações importantes:

- O histórico do chat só pode ser incluído uma vez por sessão
- O histórico do chat deve ser enviado após o prompt do sistema e antes do início do streaming de áudio
- Todas as mensagens do histórico devem ser enviadas antes do início do streaming de áudio
- Cada mensagem deve especificar o perfil de USER ou ASSISTANT
- Use o conteúdo da transcrição armazenado dos eventos `textOutput` como o valor do conteúdo em `textInput`

Recebimento de transcrições de ASR

Durante uma conversa, o Amazon Nova 2 Sonic envia transcrições de ASR por meio de eventos de saída. Cada transcrição é entregue como uma sequência de três eventos: `contentStart`, `textOutput` e `contentEnd`.

Exemplo: transcrição da fala do usuário:

1. `contentStart` - indica o início de uma transcrição:

```
{  
  "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 – contém o conteúdo real da transcrição:

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

3. contentEnd - marca o fim da transcrição:

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

O mesmo padrão de três eventos se aplica aos perfis de USER e ASSISTANT. Extraia o campo content do evento textOutput e o campo role do evento contentStart para criar seu histórico de chat.

Práticas recomendadas

Sempre armazene o histórico do chat para habilitar:

- Retomadas de sessões em diferentes dispositivos
- Registro em log e auditoria de conversas
- Preservação do contexto para interações de acompanhamento

Importante: ao salvar o histórico do chat, use saídas de texto com base no `generationStage`:

- **Speculative**: uma prévia do que Nova 2 Sonic planeja dizer, gerada antes do início da síntese de áudio
- **Final**: a transcrição real em nível de frase do que foi falado na resposta de áudio

Sempre salve a saída de texto **FINAL** em seu histórico de chat, pois ela representa o registro preciso da conversa.

Exemplo de saída **FINAL** (salve no histórico do chat):

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

Exemplo de saída **SPECULATIVE** (visualização opcional, não para histórico):

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

Configuração de ferramentas

O Amazon Nova 2 Sonic é compatível com o uso de ferramentas (também conhecidas como chamada de função), permitindo que o modelo solicite informações ou ações externas durante


conversas, como chamadas de API, consultas a banco de dados ou funções de código personalizadas. Isso permite que seu assistente de voz execute ações, recupere informações e se integre a serviços externos com base nas solicitações do usuário.

O Nova 2 Sonic apresenta chamada assíncrona de ferramentas, permitindo que a IA continue conversando naturalmente enquanto as ferramentas são executadas em segundo plano, criando uma experiência de usuário mais fluida e responsiva.

Confira abaixo as etapas simplificadas de como usar as ferramentas:

1. Definir ferramentas: especifique as ferramentas disponíveis com seus parâmetros no evento `promptStart`
2. O usuário fala: o usuário faz uma solicitação que requer uma ferramenta (como “Como está o tempo em Seattle?”)
3. Invocação da ferramenta: o Nova 2 Sonic reconhece a necessidade e envia um evento `toolUse`
4. Ferramenta de execução: sua aplicação executa a ferramenta e retorna os resultados
5. Geração de resposta: o Nova 2 Sonic incorpora os resultados em sua resposta falada

O seguinte diagrama ilustra como a ferramenta funciona:



Definição de ferramentas

As ferramentas são definidas usando um esquema JSON que descreve sua finalidade, parâmetros e entradas esperadas.

Confira os componentes e as explicações da definição de ferramentas:

- Nome: um identificador único para a ferramenta (use snake_case)
- Descrição: explicação clara do que a ferramenta faz; ajuda a IA a decidir quando usá-la
- InputSchema: um esquema JSON que define os parâmetros que a ferramenta aceita
- Propriedades: parâmetros individuais com tipos e descrições
- Obrigatório: matriz de nomes de parâmetros que devem ser fornecidos

Exemplo de definição de ferramentas

Confira uma definição simples de ferramenta de clima

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

Configuração de ferramentas no PromptStart

A configuração da ferramenta é passada para o Nova 2 Sonic no evento `promptStart`, juntamente com as configurações de saída de áudio e texto:

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

Parâmetros de escolha de ferramentas

O Nova 2 Sonic é compatível com três parâmetros de escolha de ferramentas para controlar quando e quais ferramentas são usadas. Especifique o parâmetro toolChoice na configuração da ferramenta:

- Auto (padrão): o modelo decide se alguma ferramenta é necessária e pode chamar várias ferramentas, se necessário. Oferece a máxima flexibilidade.
- Any: garante que pelo menos uma das ferramentas disponíveis seja chamada no início da geração da resposta, permitindo que o modelo selecione a mais adequada. Útil quando você tem várias bases de conhecimentos ou ferramentas e deseja garantir que uma seja usada.
- Tool: força uma ferramenta específica designada a ser chamada exatamente uma vez no início da resposta. Por exemplo, se você especificar uma ferramenta de base de conhecimentos, o modelo a consultará antes de responder, independentemente de achar que a ferramenta é necessária.

Exemplos de escolha de ferramentas

Auto (padrão)

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

Qualquer uma:

```
"toolChoice": {
```

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

Ferramenta específica:

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

Eventos de uso da ferramenta de recebimento e processamento

Quando o Amazon Nova 2 Sonic determina que uma ferramenta é necessária, ele envia um evento `toolUse` contendo:

1. `toolUseID`: identificador único para esta invocação de ferramenta
2. `ToolName`: o nome da ferramenta a ser executada
3. `Content`: string JSON contendo parâmetros extraídos da solicitação do usuário
4. `SessionID`: identificador da sessão atual
5. `Role`: definido como "TOOL" para eventos de uso de ferramenta

Exemplo de evento de uso de ferramenta

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


Processamento de etapas

1. Receber o evento toolUse do Nova 2 Sonic
2. Extrair o nome da ferramenta e os parâmetros do evento
3. Executar a lógica da sua ferramenta (chamada de API, consulta ao banco de dados etc.)
4. Retornar o resultado usando um evento toolResult

Exemplo de evento ToolResult

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

Práticas recomendadas

- Descrições claras: escreva descrições detalhadas das ferramentas para ajudar o Nova 2 Sonic a entender quando usar cada ferramenta.
- Validar parâmetros: sempre valide os parâmetros da ferramenta antes da execução para evitar erros. Defina os parâmetros da ferramenta usando o esquema JSON adequado com tipos de dados estruturados (como enumerações, números ou booleanos) em vez de strings abertas, sempre que possível.
- Tratamento de erros: retorne mensagens de erro significativas em eventos toolResult quando as ferramentas falharem.
- Execução assíncrona: aproveite a chamada assíncrona de ferramentas para manter o fluxo da conversa.
- Nomenclatura de ferramentas: use nomes descritivos e orientados à ação (como get_weather, search_database, send_email).

Chamada de ferramentas assíncronas


Diferentemente da chamada síncrona tradicional de ferramentas, em que a IA espera silenciosamente pelos resultados da ferramenta, a abordagem assíncrona do Amazon Nova 2 Sonic permite:

- Continuar aceitando a entrada do usuário enquanto as ferramentas estão em execução
- Responder a novas perguntas sem esperar pelos resultados pendentes da ferramenta
- Gerenciar várias chamadas de ferramentas simultaneamente
- Manter o fluxo natural da conversa sem pausas desconfortáveis
- Nenhuma configuração extra é necessária. A chamada de ferramentas assíncrona funciona sem configurações adicionais.

Como funciona

Quando o Nova 2 Sonic faz uma chamada de ferramenta, ele não pausa a conversa. Em vez disso, ele continua ouvindo e respondendo naturalmente até que a ferramenta retorne o resultado.


Asynchronous Tool Calling Flow



Gerenciamento das interrupções do usuário

Se um usuário alterar sua solicitação enquanto uma ferramenta está sendo executada, o Nova 2 Sonic lida com essa questão de forma inteligente, sem cancelar as chamadas de ferramentas pendentes.

Async Tool Calling with User Interruption



Cenário de exemplo

```

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]
  
```

Como funciona

Os resultados da ferramenta são sempre entregues: quando uma chamada de ferramenta é concluída, seu resultado é sempre enviado ao modelo, mesmo que o usuário tenha alterado

sua solicitação. O modelo usa seus recursos de raciocínio para determinar como lidar com as informações.

Processamento sensível ao contexto: o modelo compreende o contexto da conversa e pode lidar adequadamente com os resultados desatualizados das ferramentas. Por exemplo:

- Se o usuário disser “obrigado” depois de mudar de ideia, o modelo ainda precisará dos resultados originais para contextualizar
- Se o usuário alterar sua solicitação, o modelo poderá reconhecer os resultados originais enquanto se concentra na nova solicitação

Sem cancelamento automático: o sistema não cancela nem ignora automaticamente as chamadas de ferramentas com base nas novas entradas do usuário. Isso garante que o modelo tenha informações completas para tomar decisões inteligentes sobre como responder.

Integrações

O Amazon Nova 2 Sonic pode ser integrado a vários frameworks e plataformas para criar aplicações de IA conversacional. Essas integrações fornecem componentes pré-criados e APIs simplificadas para casos de uso comuns.

Strands Agents

O Strands Agents é um SDK simples, porém robusto, que adota uma abordagem baseada em modelos para a criação e execução de agentes de IA. De simples assistentes de conversação a fluxos de trabalho autônomos complexos, do desenvolvimento local à implantação da produção, o Strands Agents escala de acordo com as suas necessidades.

Para obter uma documentação abrangente sobre o framework do Strands, acesse a [documentação oficial do Strands](#).

O Strands BidiAgent fornece interação de áudio e texto em tempo real por meio de conexões de streaming persistentes. Diferentemente dos padrões tradicionais de solicitação-resposta, esse agente mantém conversas de longa duração com suporte para interrupções, processamento simultâneo e respostas contínuas de áudio.

Pré-requisitos:

- Python 3.8 ou superior instalado.

- Credenciais da AWS configuradas com acesso ao Amazon Bedrock
- Conhecimento básico da sintaxe async/await do Python

Exemplo de código:

Exemplo de código

Instalação:

Instale os pacotes obrigatórios:

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

Execute este exemplo:

```
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. Importação: modelos obrigatórios

```
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**: a principal classe de agente que orquestra conversas bidirecionais
- **BidiAudioIO**: gerencia a entrada e saída de áudio para interações de fala
- **BidiTextIO**: fornece saída de texto para transcrições e respostas
- **BidiNovaSonicModel**: o wrapper do modelo Nova 2 Sonic
- **Calculadora**: uma ferramenta pré-criada para operações matemáticas

2. Configurar E/S de áudio e texto

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

O **BidiAudioIO** gerencia a entrada do microfone e a saída do alto-falante, enquanto o **BidiTextIO** exibe transcrições e respostas de texto no console.

3. Inicializar o modelo

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

Crie uma instância do modelo Nova Sonic. O parâmetro de região especifica a região da AWS em que o modelo é implantado.

4. Criar e executar o agente

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

O agente é criado com:

- Modelo: o modelo Nova 2 Sonic a ser usado
- Ferramentas: lista de ferramentas que o agente pode chamar (como a calculadora)
- Entradas: entrada de áudio do microfone
- Saídas: saída de áudio para alto-falantes e saída de texto para console


Integrações do framework

O Amazon Nova 2 Sonic pode ser integrado a vários frameworks e plataformas para criar aplicações de voz sofisticadas. Os exemplos a seguir demonstram padrões de integração com frameworks populares.

Amazon Bedrock AgentCore

O Amazon Bedrock AgentCore fornece um ambiente de runtime gerenciado para a implantação de aplicações do Nova 2 Sonic com segurança e escalabilidade de nível empresarial. O AgentCore simplifica a implantação de aplicações de IA de voz em tempo real ao lidar com infraestrutura, autenticação e conectividade WebSocket.

AgentCore Architecture



Principais atributos:

- **Streaming bidirecional:** suporte nativo para a interface de streaming full-duplex do Nova Sonic com processamento de eventos em tempo real e comunicação de baixa latência.
- **Infraestrutura do WebSocket:** servidores WebSocket prontos para produção com escalabilidade automática, gerenciamento de conexões e recuperação de erros.
- **Implantação de contêineres:** implante aplicações do Nova Sonic como contêineres na infraestrutura gerenciada com escalabilidade horizontal e versionamento independente.
- **Segurança empresarial:** autenticação refinada via IAM e SigV4, isolamento de VPC e registro em log de auditoria abrangente.

A arquitetura mostra como as aplicações do cliente se conectam ao AgentCore Runtime via WebSocket com autenticação SigV4. O ambiente containerizado inclui o servidor WebSocket, a lógica da aplicação e o cliente Nova Sonic, todos se comunicando com o Nova Sonic por meio da API de streaming bidirecional.

Benefícios:

- Operações simplificadas: concentre-se na lógica da aplicação enquanto o AgentCore gerencia a infraestrutura, a escalabilidade e a confiabilidade.
- Segurança empresarial: recursos integrados de autenticação, autorização e conformidade para implantações de produção.
- Econômico: pague somente pelo que você usa com escalabilidade automática e otimização de recursos.
- Produtividade do desenvolvedor: reduza o tempo de produção com a infraestrutura gerenciada do WebSocket e a implantação de contêineres.

Casos de uso


- Assistentes de voz de atendimento ao cliente com autenticação segura
- Aplicações de voz empresariais que exigem integração com o IAM
- Plataformas de voz multilocatárias com implantações isoladas
- Aplicações habilitadas por voz que exigem trilhas de auditoria e de conformidade

Para obter documentação detalhada sobre a implantação do Nova Sonic com o AgentCore, acesse a [documentação do Amazon Bedrock AgentCore](#).

LiveKit

O LiveKit é uma plataforma de código aberto para criar aplicações de áudio e vídeo em tempo real. A integração com o Amazon Nova 2 Sonic permite que os desenvolvedores criem interfaces de voz conversacionais sem gerenciar pipelines de áudio complexos ou protocolos de sinalização.

Para exemplos detalhados de implementação e exemplos de código, acesse a [documentação da integração da AWS para o LiveKit](#).



Como funciona:

- Camada de cliente: aplicações web, móveis ou de desktop se conectam usando os SDKs de cliente LiveKit, que lidam com captura de áudio, streaming e reprodução do WebRTC.
- Servidor LiveKit: atua como um hub de comunicação em tempo real, gerenciando conexões WebRTC, roteando fluxos de áudio e gerenciando o estado da sessão com otimização de baixa latência.
- Agente LiveKit: agente baseado em Python que recebe áudio do servidor, o processa por meio do plug-in Nova Sonic e transmite as respostas de volta. Inclui recursos integrados, como detecção de atividade de voz e gerenciamento de turnos.
- Amazon Nova 2 Sonic: processa o fluxo de áudio por meio da API de streaming bidirecional, realizando reconhecimento de voz, compreensão da linguagem natural e gerando respostas conversacionais com voz sintetizada.


Pipecat

O Pipecat é um framework para criar aplicações de IA conversacional de voz e multimodais. Ele fornece uma arquitetura modular baseada em pipelines que orquestra vários componentes para criar aplicações de voz inteligentes com o Amazon Nova Sonic e outros serviços da AWS.

Para exemplos detalhados de implementação e exemplos de código, acesse a [documentação de integração da AWS para o PipeCat](#).

Principais atributos:

- Arquitetura de pipeline: framework modular baseado em Python para compor componentes de IA de voz, incluindo ASR, NLU, TTS e muito mais.
- Fluxos do Pipecat: framework de gerenciamento de estado para criar lógica conversacional complexa e execução de ferramentas.
- Suporte a WebRTC: integração integrada com o Daily e outros provedores WebRTC para streaming de áudio em tempo real.
- Integração da AWS: suporte nativo para o Amazon Bedrock, Amazon Transcribe e Amazon Polly.



A arquitetura inclui:

- Transporte WebRTC: streaming de áudio em tempo real entre dispositivos cliente e servidor de aplicações.
- Detecção de atividade de voz (VAD): Silero VAD com detecção de fala configurável e supressão de ruído.
- Reconhecimento de voz: Amazon Transcribe para conversão precisa e em tempo real de fala em texto.
- Compreensão da linguagem natural: Amazon Nova Pro no Bedrock com inferência otimizada para latência.
- Execução da ferramenta: Pipecat Flows para integração de API e chamadas de serviço de backend.
- Geração de respostas: Amazon Nova Pro para respostas coerentes e sensíveis ao contexto.

- Conversão de texto em fala: Amazon Polly com vozes generativas para uma saída de fala realista.


Implantar na AWS

Implante suas aplicações do Nova Sonic na AWS usando a infraestrutura como código com o AWS CDK (Cloud Development Kit). Essa abordagem fornece implantações reproduzíveis e controladas por versão com as melhores práticas incorporadas.

Opções de implantação

- Amazon ECS (Elastic Container Service): orquestração de contêineres totalmente gerenciada com integração com o Application Load Balancer, ajuste de escala automático e execução do Fargate sem servidor.
- Amazon EKS (Elastic Kubernetes Services): Kubernetes gerenciado para orquestração complexa, redes avançadas, implantações em várias regiões e amplo ecossistema de ferramentas.
- AWS CDK: o AWS CDK permite que você defina a infraestrutura de nuvem usando linguagens de programação familiares.

Para ver um exemplo completo e pronto para produção da implantação do Nova Sonic com o AWS CDK, consulte o [exemplo de conversão de fala em fala do CDK](#) no GitHub. Esse exemplo demonstra:



- Configuração completa da infraestrutura do CDK com TypeScript
- Implementação do servidor WebSocket para comunicação em tempo real
- Implantação de contêineres com o ECS e Fargate
- Configuração do Application Load Balancer para suporte do WebSocket
- Configuração de grupos de segurança e redes da VPC
- Monitoramento e registro em log do CloudWatch
- Práticas recomendadas para implantações de produção


Sistemas multiagentes

A arquitetura multiagente é um padrão amplamente usado para projetar assistentes de IA que lidam com tarefas complexas. Em um assistente de voz desenvolvido pelo Nova 2 Sonic, essa arquitetura coordena vários agentes especializados, em que cada agente opera de forma independente para permitir processamento paralelo, design modular e soluções escaláveis.

O Nova Sonic atua como o orquestrador em um sistema multiagente, executando duas funções principais:

Gerenciamento do fluxo de conversas: garante que todas as informações necessárias sejam coletadas antes de prosseguir para a próxima etapa da conversa.

Classificação de intenção: analisa as consultas dos usuários e as encaminha para o subagente especializado apropriado.



O diagrama acima mostra um assistente de voz bancário que usa uma arquitetura multiagente. O fluxo da conversa começa com uma saudação e a coleta do nome do usuário e, em seguida, trata de consultas relacionadas a bancos ou hipotecas por meio de subagentes especializados.

Exemplo de fluxo de conversa:

1. O usuário se conecta ao assistente de voz.
2. Nova 2 Sonic: “Olá! Qual é o seu nome?”
3. Usuário: “Meu nome é John”
4. Nova 2 Sonic: “Oi John, como posso ajudá-lo hoje?”
5. Usuário: “Quero verificar o saldo da minha conta”
6. Nova 2 Sonic: [Rotas para o agente de autenticação]
7. Agente de autenticação: “Por favor, forneça o ID da sua conta”
8. Usuário: “12345”
9. Agente de autenticação: [Verifica a identidade]
10. Nova 2 Sonic: [Rotas para o agente bancário]

11 Agente bancário: “Seu saldo atual é de USD 5.431,10”

Embora este exemplo demonstre subagentes usando o framework Strands Agents implantado no Amazon Bedrock AgentCore, a arquitetura é flexível. É possível escolher:

- Seu framework de agente de preferência
- Qualquer provedor de LLM
- Opções de hospedagem personalizadas
- Padrões de orquestração diferentes

Benefícios:

- Modularidade: cada agente se concentra em um domínio específico, facilitando a manutenção e a atualização do sistema.
- Escalabilidade: adicione novos agentes sem modificar os existentes, permitindo que seu sistema cresça de acordo com suas necessidades.
- Processamento paralelo: vários agentes podem trabalhar simultaneamente, melhorando os tempos de resposta para consultas complexas.
- Especialização: cada agente pode ser otimizado para sua tarefa específica, usando as ferramentas e bases de conhecimentos mais adequadas.
- Isolamento de falhas: se um agente falhar, outros continuarão funcionando, melhorando a confiabilidade geral do sistema.

Consulte [este blog](#) para obter mais detalhes e exemplos de código.

Consulte o [Nova Sonic Workshop Multi-Agent Lab](#) para ver exemplos práticos.

Integração de telefonia

O Amazon Nova 2 Sonic se integra aos provedores de telefonia para permitir que aplicações de voz baseadas em IA sejam acessíveis por meio de chamadas telefônicas. Este guia aborda a integração com Twilio, Vonage e outros sistemas baseados em SIP para criar soluções de central de atendimento e agentes de voz.

Twilio: plataforma de comunicação em nuvem com recursos programáveis de streaming de voz e mídia.

Vonage: APIs de comunicação global com voz, streaming de áudio WebSocket e conectividade SIP.

A AWS fornece um exemplo abrangente de implementação demonstrando o Nova Sonic em um ambiente de central de atendimento com analytics em tempo real e integração de telefonia.

Repositório: [Exemplo de central de atendimento do Sonic com telefonia](#)

Sistemas avançados com o Amazon Nova

Visão geral

Esta seção fornece orientação abrangente para usuários avançados que implementam padrões complexos com modelos Nova. Esses recursos permitem aplicações sofisticadas, incluindo integração de ferramentas, geração aumentada via recuperação (RAG) e agentes autônomos de IA.

Pensamento estendido no Amazon Nova 2

O Amazon Nova 2 Lite apresenta recursos de pensamento estendido que permitem que o modelo realize um raciocínio mais profundo para problemas complexos. Esse recurso opcional oferece controle sobre quando e como o modelo aloca recursos computacionais adicionais para pensar em tarefas desafiadoras.

Como funciona o pensamento estendido

O Amazon Nova 2 apresenta o pensamento estendido como uma capacidade híbrida. Você tem controle total:

- Pensamento estendido DESATIVADO (padrão): o Amazon Nova 2 opera com raciocínio latente eficiente, ideal para tarefas diárias e aplicações de alto volume.
- Pensamento estendido ATIVADO: o Amazon Nova 2 usa o melhor raciocínio explícito, passo a passo, para problemas complexos que exigem uma análise profunda.

Esforço de raciocínio

Confira a seguir diferentes níveis de esforço de raciocínio.

Baixo esforço (`maxReasoningeffort:"low"`)

Ideal para: tarefas com maior complexidade que exigem pensamento estruturado. Por exemplo, você pode usar para análise de código e sugestões de melhoria em que o modelo precisa considerar cuidadosamente a qualidade do código existente, tarefas de análise que exigem consideração cuidadosa de vários fatores ou cenários de solução de problemas que se beneficiam de uma abordagem metódica. O baixo esforço é ideal para tarefas compostas em que o raciocínio básico melhora a precisão sem exigir um planejamento profundo em várias etapas.

Esforço médio (maxReasoningEffort: "medium")

Ideal para: tarefas de várias etapas e fluxos de trabalho de codificação. Por exemplo, você pode usar para desenvolvimento e depuração de software em que o modelo precisa entender a estrutura de código existente antes de implementar alterações, geração de código que requer coordenação entre vários arquivos ou componentes, cálculos de várias etapas com interdependências ou tarefas de planejamento com várias restrições. O esforço médio é ideal para fluxos de trabalho agênticos que coordenam várias ferramentas e exigem que o modelo mantenha o contexto em várias operações sequenciais.

Alto esforço (maxReasoningEffort: "high")

Ideal para: raciocínio lógico-científico e resolução avançada de problemas. Por exemplo, você pode usar para comprovações e problemas matemáticos avançados que exigem verificação passo a passo rigorosa, análise científica e tarefas de pesquisa que exigem investigação aprofundada, design de sistema complexo com considerações de arquitetura em várias dimensões ou cenários críticos de tomada de decisão com implicações significativas. O alto esforço proporciona a máxima precisão para tarefas que exigem raciocínio sofisticado, avaliação cuidadosa das alternativas e validação completa das conclusões.

Início rápido: habilitação do pensamento estendido

O pensamento estendido é controlado por meio do parâmetro `reasoningConfig`.

```
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"])

```

Parâmetros de raciocínio:

- type: enabled ou disabled (padrão: disabled)
- maxReasoningEffort: low, medium, ou high

Note

Temperature, topP e topK não podem ser usados com maxReasoningEffort definido como high. Usar esses parâmetros juntos gera um erro.

Para obter exemplos completos de código que utiliza o pensamento estendido, consulte [the section called “Biblioteca de códigos”](#).

Estrutura de respostas

Quando você habilita o pensamento estendido, as respostas incluem blocos reasoningContent seguidos por blocos de conteúdo text:

```
{
```

```

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

```

Note

Com o Amazon Nova 2, o conteúdo de raciocínio é exibido como [REDACTED]. Você ainda é cobrado pelos tokens de raciocínio, pois eles contribuem para melhorar a qualidade da saída. Esse campo foi incluído na estrutura de respostas para preservar a opção de expor o conteúdo de raciocínio no futuro. Estamos trabalhando ativamente com os clientes para determinar a melhor abordagem para apresentar o processo de raciocínio do modelo. O conteúdo do raciocínio é exibido como [REDACTED]. Você ainda é cobrado pelos tokens de raciocínio, pois eles contribuem para melhorar a qualidade da resposta.

Opções de configuração

O Amazon Nova 2 introduz um novo parâmetro `reasoningConfig` que você pode adicionar à sua estrutura de solicitação conversa existente para permitir o raciocínio:

```

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

```

```
}  
}
```

Parâmetros:

- `type`: alternar entre "enabled" e "disabled" (o padrão é "disabled")
- **`maxReasoningEffort`**: quando habilitado, controla a profundidade do raciocínio
- "low": tarefas moderadamente complexas
- "medium": problemas complexos que exigem análises substanciais
- "high": o raciocínio mais completo para tarefas altamente complexas

Note

ao usar "high", `temp`, `topP` e `maxToken` devem ser desativados. Nesse modo, o modelo realiza uma análise mais profunda para encontrar a melhor solução. Esse processamento mais completo pode gerar uma saída que excede 65 mil tokens. A quantidade exata depende da complexidade da sua solicitação, mas, em alguns problemas, vimos um aumento de até 128 mil tokens. Isso garante que você obtenha um raciocínio completo e de alta qualidade, em vez de resultados truncados.

Modelos compatíveis

O pensamento estendido está atualmente disponível em: Amazon Nova 2 Lite (`us.amazon.nova-2-lite-v1:0`)

Raciocínio estendido com o uso de ferramentas

O pensamento estendido funciona perfeitamente com a chamada de ferramentas, permitindo que o Amazon Nova raciocine sobre quais ferramentas usar e como interpretar seus resultados.

Compreensão de preços e tokens de raciocínio

Tipos de token

Os tokens de pensamento estendido são cobrados como tokens de saída:

- Tokens de entrada: o conteúdo original da sua solicitação (preço de entrada padrão)
- Tokens de saída: inclui tokens de raciocínio e o conteúdo final da resposta visível (preço de saída padrão)

Detalhamento de uso

Todos os três tipos de token estão incluídos em suas métricas de uso e cobrança. Os tokens de raciocínio têm o mesmo preço dos tokens de saída e aparecerão como “REDACTED” na resposta do modelo.

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

Perguntas frequentes

Por que o Amazon Nova 2 Lite mostra “[REDACTED]” como conteúdo de raciocínio em vez de exibir o processo de raciocínio do modelo?

Nosso foco principal neste lançamento é garantir que o Nova 2 ofereça a melhor inteligência da categoria para suas tarefas, e você verá isso refletido na melhoria da precisão.

Reconhecemos que a visibilidade do processo de raciocínio é valiosa, e temos notado um grande interesse por parte dos clientes em compreender o processo de pensamento do modelo ao resolver problemas.

Estamos procurando formas de disponibilizar esse recurso em breve.

Você ainda será cobrado pelos tokens de raciocínio, pois eles representam o trabalho real realizado para melhorar a qualidade da resposta,

o que será contabilizado em outputTokens junto com os tokens de resposta.

Como saberei se o pensamento estendido está funcionando se o raciocínio estiver omitido?

Você pode confirmar se o pensamento estendido está funcionando verificando a saída em busca de blocos `reasoningContent` na resposta (eles só aparecem quando o raciocínio está habilitado)

Uso de ferramentas (chamada de função)

As ferramentas ampliam os recursos do Amazon Nova conectando o modelo a funcionalidades externas, como APIs, bancos de dados e ambientes de execução de código. O uso de ferramentas permite que o Amazon Nova acesse informações em tempo real, realize cálculos e interaja com sistemas externos.

Compreensão do fluxo de trabalho do uso de ferramentas

O uso de ferramentas com o Amazon Nova envolve três fases principais:

Consulta do usuário e definição da ferramenta

Defina ferramentas fornecendo esquemas JSON que descrevam a funcionalidade e os requisitos de entrada de cada ferramenta. A configuração da ferramenta deve incluir detalhes explícitos sobre quando e como usar cada ferramenta.

Seleção da ferramenta

Quando um usuário envia uma mensagem, o Amazon Nova a analisa para determinar se uma ferramenta é necessária. Essa escolha automática de ferramenta examina o contexto e decide qual ferramenta (se houver) invocar. Se o Amazon Nova identificar uma ferramenta adequada, ele retornará o nome da ferramenta e os parâmetros necessários.

Você é responsável por executar a ferramenta com base na solicitação do modelo. Isso significa que é necessário escrever o código que invoca a funcionalidade da ferramenta e processa os parâmetros de entrada fornecidos pelo modelo.

Retorno dos resultados

Depois de executar a ferramenta, envie os resultados de volta para o Amazon Nova em um formato estruturado usando JSON ou uma combinação de texto e imagens. O Amazon Nova incorpora a saída da ferramenta à resposta final. Se ocorrerem erros durante a execução, indique isso na resposta da ferramenta para permitir que o Amazon Nova se ajuste adequadamente.

Criar uma ferramenta

Defina ferramentas usando uma configuração de ferramenta que inclua uma matriz de ferramentas e, opcionalmente, um parâmetro de escolha de ferramenta. Cada especificação de ferramenta deve incluir:

- Nome: um identificador claro para a ferramenta
- Descrição: explicação concisa da funcionalidade da ferramenta
- Esquema de entrada: esquema JSON que define os parâmetros obrigatórios e opcionais

Exemplo Exemplo de configuração de ferramenta

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

Práticas recomendadas para definições de ferramentas

- Certifique-se de que o nome e a descrição transmitam explicitamente a funcionalidade exata da ferramenta; evite ferramentas que sejam muito semelhantes semanticamente

- Inclua os principais diferenciais na descrição para ajudar o modelo a distinguir entre ferramentas similares
- Limite os esquemas JSON a duas camadas de aninhamento para obter o melhor desempenho
- Restrinja as entradas usando tipos de esquema (por exemplo, enum, int, float) em vez de descrever a estrutura em texto simples
- Indique parâmetros obrigatórios vs opcionais usando a notação de esquema JSON (por exemplo, "required": ["param1", "param2"])
- Valide seu esquema JSON usando um validador padrão antes de enviar
- Coloque argumentos longos de string por último no esquema e evite aninhá-los

Saída estruturada com decodificação restrita

Os modelos do Amazon Nova utilizam a decodificação restrita para garantir alta confiabilidade nas saídas geradas. Essa técnica usa gramática para restringir possíveis tokens em cada etapa de geração, evitando chaves inválidas e impondo tipos de dados corretos com base no esquema definido.

Example Exemplo de saída estruturada

```
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"}
}
}

```

Opções de escolha de ferramentas

O Amazon Nova é compatível com três parâmetros de escolha de ferramentas:

Ferramenta

A ferramenta especificada será chamada uma vez, ideal para casos de uso de saída estruturada

Any

Uma das ferramentas fornecidas será chamada pelo menos uma vez, útil para cenários de seleção de API

Auto

O modelo decide se deve chamar uma ferramenta e quantas ferramentas chamar (comportamento padrão)

Chamar uma ferramenta

Se o Amazon Nova decidir chamar uma ferramenta, um bloco de uso da ferramenta será retornado como parte da mensagem do assistente com `stopReason` definido como `"tool_use"`. O bloco da ferramenta contém o nome da ferramenta e suas entradas.

Note

Execute as seguintes seções de código sequencialmente (Chamando uma ferramenta → Processando chamada da ferramenta → Retornando resultados da ferramenta) em uma única sessão de Python. Para executar os exemplos novamente, reinicie sua sessão de Python.

Example Chamada de uma ferramenta

```
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']}")

```

Processamento de chamadas de ferramentas

Extraia o nome e os argumentos da ferramenta da mensagem e, em seguida, invoque a ferramenta:

```

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"])
```

Retornar resultados da ferramenta

Retorne os resultados da ferramenta usando o esquema ToolResultBlock:

```
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}")
```

Tratamento de erros

Relate os erros ao Amazon Nova para permitir a modificação da solicitação e tente novamente:

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

Considerações sobre segurança

- Valide a existência de ferramentas antes de invocá-las
- Certifique-se de que as entradas estejam formatadas corretamente
- Verifique se as permissões apropriadas estão em vigor antes da execução da ferramenta
- Confie nos detalhes da sessão em vez de permitir que o Amazon Nova injete informações do usuário nas chamadas de ferramentas
- Lembre-se de que os LLMs podem gerar alucinações nas chamadas de ferramentas; sempre valide antes da execução

Ferramentas de sistema integradas

Os modelos do Amazon Nova 2.0 incluem ferramentas integradas totalmente gerenciadas que não exigem implementação personalizada. Habilite essas ferramentas com uma simples alternância na API Converse.

Interpretador de Código

O Code Interpreter permite que o Nova execute com segurança o código Python em ambientes de sandbox isolados. Essa ferramenta foi projetada para cálculos matemáticos, operações lógicas e algoritmos iterativos.

Note

O Interpretador de Código está disponível nas regiões IAD, PDX e NRT da AWS. Para garantir que suas solicitações sejam encaminhadas para uma região com suporte, use o Global CRIS. Ao usar as chaves da API do Bedrock, você precisará adicionar permissões `InvokeTool` manualmente às definições da política. O perfil padrão do Bedrock não permite a ação `InvokeTool`.

Habilite o Interpretador de Código especificando o parâmetro `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"])
```

O interpretador executa esse código em uma sandbox e retorna resultados em um esquema padrão:

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

Web grounding

A Ancoragem na Web permite que o Amazon Nova acesse informações em tempo real da internet, fornecendo respostas atualizadas e reduzindo as alucinações. Habilite especificando a ferramenta do sistema nova_grounding:

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

Para obter informações detalhadas sobre a Ancoragem na Web, consulte [the section called “Web grounding”](#).

Protocolo de contexto para modelos (MCP)

O protocolo de contexto para modelos (MCP) é um padrão aberto que possibilita conexões bidirecionais seguras entre suas fontes de dados e as ferramentas baseadas em IA. Em vez de

escrever adaptadores personalizados para cada API ou serviço, execute um servidor MCP e permita que o Amazon Nova descubra suas ferramentas automaticamente por meio de uma ponte de cliente.

Uma vez conectado, o Amazon Nova trata essas ferramentas de MCP como qualquer outra integração externa: ele decide quando chamá-las, envia os parâmetros necessários e incorpora os resultados em sua resposta. Usar o Amazon Nova com o Strands torna essa tarefa mais simples por meio de um MCPClient integrado que gerencia automaticamente a descoberta, a conexão e o mapeamento de resultados.

Criar agentes de IA

Os modelos do Amazon Nova são otimizados para criar agentes de IA com o Amazon Nova Act. Os modelos oferecem um uso aprimorado das ferramentas, melhor raciocínio para tarefas de várias etapas, maior capacidade de manter o contexto em fluxos de trabalho complexos de agentes e compatibilidade com ferramentas MCP remotas.

Crie um agente

Agentes de IA criados com o Nova podem orquestrar várias chamadas de ferramentas, manter o contexto em interações estendidas e corrigir o curso quando necessário. O pensamento estendido transforma os fluxos de trabalho agênticos, permitindo o raciocínio sistemático por meio de metas complexas. Considere usar um SDK de framework de planejamento, como o Strands Agents, para tornar o processo de planejamento e execução de seus sistemas de agentes mais robusto.

Padrões de design do agente

Ao projetar agentes com o Nova:

- Habilite o raciocínio médio ou alto para obter melhores resultados em fluxos de trabalho complexos de várias etapas que exigem planejamento e verificação
- Implemente a opção de ferramentas auto para permitir a seleção flexível de ferramentas em todas as interações do agente
- Desenvolva um tratamento de erros que permita que os agentes se recuperem e tentem novamente com abordagens modificadas
- Mantenha o histórico de conversas para preservar o contexto entre as interações dos agentes
- Implemente mecanismos robustos de filtragem e moderação de conteúdo em todo o conteúdo não controlado que seu sistema de agentes consome. Por exemplo, a Amazon oferece as Barreiras de

Proteção para Amazon Bedrock, um recurso projetado para aplicar proteções em vários modelos de base, bases de conhecimentos e agentes. Essas barreiras de proteção podem filtrar conteúdo prejudicial, bloquear tópicos proibidos e ocultar informações confidenciais, como informações de identificação pessoal.

Exemplo de agente de várias ferramentas

```
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"
        #}
    #}
#}
)

```

Invocar um agente

A invocação do agente envolve o gerenciamento do fluxo de conversação, o processamento de chamadas de ferramentas e a manutenção do estado em várias interações.

Respostas do agente via streaming

Transmita respostas via streaming para fornecer visibilidade em tempo real do raciocínio e das ações do 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)

```

Gerenciamento de estados do agente

Mantenha o histórico de conversas e os resultados da ferramenta para preservar o contexto; o exemplo abaixo demonstra isso em um único turno, mas o desenvolvedor pode determinar como orquestrar o sistema geral do agente com base nos requisitos do fluxo de trabalho. Além disso, as ferramentas da Amazon Web Services, como o Strands, gerenciam o contexto do agente e o estado da ferramenta em nome do desenvolvedor.

```
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  
#)
```

Práticas recomendadas de agentes

Para obter mais informações sobre as práticas recomendadas de agentes, consulte [the section called “Práticas recomendadas”](#).

Para obter orientação sobre o desenvolvimento de agentes de IA conversacional, consulte [Conversão de fala em fala](#).

Web grounding

A Ancoragem na Web permite que o Amazon Nova pesquise na web informações atuais e forneça respostas com citações. Esse recurso é útil para consultas que exigem informações atualizadas além dos dados de treinamento do modelo.

Como funciona o Web Grounding

Quando o Web Grounding está habilitado para um prompt, as seguintes etapas são executadas:

1. Configuração da solicitação: sua aplicação envia um prompt de usuário para a API do Amazon Bedrock com `nova_grounding` habilitado como `systemTool`.
2. Pesquisa e análise: o modelo determina se é necessário pesquisar, realiza uma ou mais pesquisas por informações relevantes e avalia se pesquisas adicionais são necessárias para expandir sua compreensão ou se aprofundar em subtópicos específicos.
3. Geração de resposta: o Amazon Nova sintetiza automaticamente as informações dos resultados da pesquisa para gerar uma resposta final da API baseada em informações em tempo real, completa com citações de suas fontes.

Como usar o Web Grounding

Para obter exemplos completos de código que utiliza a Ancoragem na Web, consulte a seção Exemplos de código.

Para incluir a Ancoragem na Web em seus resultados, especifique o seguinte parâmetro `systemTool` em seu bloco `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)
```

Disponibilidade regional

Atualmente, a Ancoragem na Web está disponível apenas nas regiões dos EUA e é compatível somente com os perfis CRIS dos EUA.

Estrutura de respostas

O seguinte é um exemplo de resposta. A resposta foi abreviada para ser breve:

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

Cada citação inclui:

- **text**: um segmento da resposta gerada pelo modelo.
- **citationsContent**: o contêiner primário dos dados de citação relacionados a um segmento de texto.
- **citations**: um contêiner com **citationsContent** que contém a localização de uma citação.
- **location**: um contêiner com **citations** que contém a fonte de uma citação.
- **web**: um contêiner com **location** que contém os detalhes da fonte da web.
- **url**: o endereço completo da web (URL) da fonte da citação.

- `domain`: o domínio raiz do URL da fonte.

Segurança da ancoragem

Seus dados nunca saem da infraestrutura AWS. As consultas geradas pelo modelo permanecem nos serviços AWS e nunca são enviadas para a internet geral. Nosso abrangente índice interno de pesquisa na web e gráficos de conhecimento priorizam fontes confiáveis e de alta qualidade e filtram conteúdo malicioso na entrada. Por fim, protegemos seu aplicativo contra injeção indireta de prompt e desinformação com a filtragem de runtime (observe que essa mitigação é limitada para idiomas que não sejam o inglês).

Tratamento de erros

Não inclua uma entrada `toolSpec` com o nome `nova_grounding`. Incluir uma ferramenta com esse nome resultará em um erro.

Veja a seguir uma lista de possíveis erros que podem ocorrer ao usar o Web Grounding:

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

Permissões necessárias para ferramentas integradas

Para garantir que seu perfil tenha acesso à Ancoragem na Web no Amazon Bedrock, você tem duas opções:

1. Habilite o `BedrockFullAccess` em seu perfil do IAM: se seu perfil tiver `BedrockFullAccess`, ela terá acesso automático à Ancoragem na Web.
2. Adicione permissões específicas (se necessário): se você precisar de um controle de acesso mais granular, adicione essa política à política do IAM do seu perfil, substituindo o ID da conta pelo ID da sua Conta da AWS:

```
{
  "Statement": [
    {
      "Effect": "Allow",
```

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

A Ancoragem na Web tem a chave de condição `aws:requestedRegion` definida como “unspecified”. Se suas políticas existentes ou Políticas de Controle de Serviços (SCPs) impuserem essa condição, você poderá encontrar problemas de acesso. Atualizar a condição para permitir uma `requestedRegion` “não especificada” pode resolver esse problema.

 Note

Ao habilitar a ferramenta Web Grounding, você se torna responsável pelo seu uso, e por qualquer uso por parte de seus usuários finais, do conteúdo gerado que incorpore informações fundamentadas. Você saberá quando sua resposta incluir informações fundamentadas em citações ou links para o material de origem. Você deve reter e exibir essas citações e links no resultado que fornecer aos seus usuários finais.

 Note

O Web Grounding tem um custo adicional. Para obter mais informações, acesse [Preços do AWS Bedrock](#).

Guia de engenharia de prompts

A engenharia de prompts é a prática de criar instruções para se comunicar de forma eficaz com grandes modelos de linguagem (LLMs), como o Amazon Nova. Ela permite que você controle o comportamento do modelo, melhore a qualidade da saída e crie aplicações confiáveis baseadas em IA.

A engenharia de prompts eficaz envolve a criação de entradas que orientam os modelos para gerar as saídas desejadas. Um prompt bem elaborado fornece instruções claras, contexto relevante e dados de entrada formatados corretamente.

O que é a engenharia de prompts

Engenharia de prompts refere-se à prática de otimizar a entrada de texto para um grande modelo de linguagem (LLM) para melhorar a saída e obter as respostas desejadas. Os prompts ajudam um LLM a executar uma ampla variedade de tarefas, incluindo classificação, respostas a perguntas, geração de código, escrita criativa e muito mais. A qualidade dos prompts que você fornece a um LLM pode afetar a qualidade das respostas do modelo. Esta seção fornece todas as informações necessárias para começar a usar a engenharia de prompts. Também abrange ferramentas para ajudar a encontrar o melhor formato de prompt possível para o caso de uso ao usar um LLM no Amazon Bedrock

A eficácia dos prompts depende da qualidade das informações fornecidas e da habilidade na elaboração do próprio prompt. Os prompts podem incluir instruções, perguntas, detalhes contextuais, entradas e exemplos para orientar o modelo de forma eficaz e melhorar a qualidade dos resultados. Este documento descreve estratégias e táticas para otimizar o desempenho da família de modelos do Amazon Nova 2 Sonic. Os métodos aqui apresentados podem ser empregados em várias combinações para ampliar sua eficácia. Incentivamos que você realize experimentações para identificar as abordagens mais adequadas às suas necessidades específicas.

Conceitos básicos da engenharia de prompts

Antes de iniciar a engenharia de prompts, recomendamos que você tenha os seguintes elementos prontos para que possa desenvolver iterativamente o prompt mais adequado para seu caso de uso:

Definir seu caso de uso

Defina seu caso de uso em quatro dimensões:

- **Tarefa:** defina o que você deseja que o modelo realize. Isso determina a técnica correta de para prompts.
- **Perfil:** defina o perfil que o modelo deve assumir para realizar essa tarefa. Os modelos do Amazon Nova são compatíveis com três perfis (sistema, usuário ou assistente).
- **Estilo de resposta:** defina a estrutura ou o estilo de resposta que o modelo deve seguir com base no público, como JSON, markdown ou conversacional.
- **Instruções:** defina o conjunto de instruções que o modelo deve seguir para responder de acordo com os critérios de sucesso.

Estabelecer critérios de sucesso

Defina critérios de sucesso ou métricas de avaliação. Você pode fornecer uma lista de critérios ou métricas de avaliação específicas, como tamanho, pontuação BLEU, ROUGE, formato, factualidade e fidelidade.

Elaborar um prompt

Crie um prompt inicial incorporando sua tarefa, perfil, estilo de resposta e instruções. Faça iterações com base nos resultados.

A eficácia dos prompts depende da qualidade das informações que você fornece.

Práticas recomendadas gerais

As práticas recomendadas a seguir se aplicam principalmente aos modelos de texto do Amazon Nova, mas você pode aplicá-las a outros modelos, além das práticas recomendadas específicas da modalidade.

Para obter mais informações sobre como gerar prompts para entradas multimodais, consulte [Gerar prompts para entradas multimodais](#). Para obter informações sobre como gerar prompts para entradas de fala, consulte [Prompts de conversa por voz](#).

Compreensão dos perfis

Os modelos do Amazon Nova permitem que você estruture prompts por meio do uso de três perfis distintos: sistema, usuário e assistente.

- **Sistema (opcional):** embora não seja obrigatório, estabelece os parâmetros comportamentais gerais do assistente. Ela também pode ser utilizada para fornecer instruções e diretrizes adicionais que o usuário deseja que o modelo siga durante a conversa.

- **Usuário:** pode, opcionalmente, transmitir o contexto, as tarefas, as instruções e o resultado desejado junto com a consulta do usuário.
- **Assistente:** ajuda a orientar o modelo para obter a resposta pretendida.

Tópicos

- [Criar prompts precisos](#)
- [Dar ênfase às seções do prompt](#)
- [Usar o perfil do sistema](#)
- [Fornecer exemplos \(criação de prompts few-shot\)](#)
- [Sistemas de chamada de ferramentas](#)
- [Técnicas avançadas de geração de prompts](#)

Criar prompts precisos

Elaborar consultas específicas de usuários é crucial na engenharia de prompts. Consultas bem elaboradas orientam os modelos de compreensão de texto do Amazon Nova para gerar respostas precisas e pertinentes. Para elaborar essas consultas, é essencial começar fornecendo informações contextuais na consulta. O contexto fornecido ajuda a situar melhor o modelo, alinhando-o a cenários claros do usuário-alvo, aumentando assim a relevância e a coerência da saída.

Fornecer informações contextuais e específicas

Os modelos funcionarão melhor se as instruções forem claras, bem estruturadas, curtas e específicas. Esta orientação de modelo de prompt se aplica tanto ao prompt do usuário quanto ao prompt do sistema.

Modelo de 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}"""

```

Exemplo: informações específicas e contextuais

Confira abaixo um exemplo de um prompt que é reescrito com informações específicas e contextuais. Adicionar mais informações contextuais ajuda o modelo a se orientar para obter o comportamento desejado.

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]

- Seja claro: ao solicitar o modelo, tente manter as instruções o mais claras possível de uma forma que um humano as entenda, em vez de uma máquina (por exemplo, uma lista no estilo JSON).
- Seja específico: forneça instruções específicas ao modelo sobre qual é a tarefa, qual é a saída esperada e qualquer contexto adicional para ajudar o modelo a responder da maneira que você deseja.

Especifique o formato e o estilo de saída

Caso queira que o Amazon Nova 2 gere respostas adaptadas às suas necessidades específicas, você pode especificar o formato e o estilo da saída. Por exemplo, se você quiser gerar respostas somente em JSON ou restringir o tamanho da resposta a um número máximo de palavras, marcadores ou parágrafos. Isso permite que o Amazon Nova 2 entenda melhor seus requisitos e gere saídas mais relevantes e fáceis de analisar.

Use letras maiúsculas e palavras fortes, como FAÇA, NÃO FAÇA, DEVE, para enfatizar as regras que você deseja que o modelo obedeça estritamente. Por exemplo, se você quiser apenas um objeto JSON na resposta, você pode instruir o modelo dizendo “Você DEVE responder somente no formato JSON. NÃO use nenhum outro formato ao responder à pergunta.”

Confira abaixo exemplos de prompts que foram reescritos com informações específicas e contextuais. Adicionar mais informações contextuais ajuda o modelo a se orientar para obter o comportamento desejado.

Exemplo 1: fornecer detalhes adicionais

Adicionar detalhes adicionais sobre a formatação da resposta pode ajudar o modelo a alcançar o resultado desejado. Alguns dos outros formatos de resposta comumente usados incluem 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
` ``

```

## Exemplo 2: fornecer restrições de estilo

Nesse caso, o prompt com restrições de estilo fornece informações abrangentes sobre as restrições a serem seguidas e o formato de resposta desejado. Conforme observado na resposta, o prompt otimizado se alinha mais de perto com a brevidade solicitada e a estrutura de lista com marcadores.

### 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.

### Exemplo 3: limitar o formato da resposta

Aqui, o prompt com o formato de resposta força o modelo a responder somente com o número da categoria e o limita entre 1 e 10, em vez de ser altamente detalhado.

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

## Fornecer seções claras do prompt

Além do contexto inicial, um formato de consulta estruturado desempenha um papel significativo na otimização das interações com o modelo de linguagem. A separação de partes distintas da entrada com delimitadores garante clareza e aprimora a capacidade dos modelos do Amazon Nova 2 de entender a estrutura da consulta. Outra forma eficaz é usar listas numeradas ou com marcadores, que podem ajudar a dividir a tarefa em etapas gerenciáveis e fornecer um esquema claro das ações que precisam ser executadas. Essa abordagem estruturada ajuda a reduzir a ambiguidade e a melhorar a precisão das respostas geradas.

Exemplo: criar um prompt dividido em seções

Observe como, na coluna Prompt dividido em seções, o prompt é mais claro e tem seções delineadas para diferentes entidades, como Tarefas, Contexto, Requisitos e outras, em comparação com as instruções na coluna Prompt não dividido em seções.

## 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 CO2 levels rise, more of it is absorbed by the oceans, making them more acidic. This is particularly harmful to marine life, including coral reefs. Coral reefs are crucial for marine biodiversity but are now dying at an alarming rate.

## **Individual Actions to Mitigate Climate Change**

You might think that since climate change is a huge problem, one person can't make a difference. But even small actions can add up to make a big impact.

### **1. Reduce, Reuse, Recycle**

Try to minimize waste by:

- **Reducing:** Buy fewer items and choose products with less packaging.
- **Reusing:** Use reusable bags, bottles, and containers.
- **Recycling:** Make sure to recycle paper, plastic, and glass properly.

### **2. Conserve Energy**

Small changes can lead to big savings:

- Turn off lights when you leave a room.
- Unplug devices that you're not using.
- Use energy-efficient bulbs and appliances.

### **3. Use Less Meat**

Livestock farming is a major contributor to greenhouse gas emissions. By eating less meat, especially beef, you can reduce your carbon footprint.

### **4. Support Renewable Energy**

If possible, support or switch to renewable energy sources like solar or wind power. Even advocating for these options in your community can make a difference.

### **5. Educate Yourself and Others**

Knowledge is power. The more you know about climate change, the more you can help others understand it. Share facts and encourage your friends and family to take action too.

#### #### Conclusion

Climate change is a pressing issue that affects everyone on the planet. By understanding its basics, recognizing its current impacts, and taking individual actions, you can play a crucial role in mitigating its effects. Remember, every small step counts, and together, we can make a big difference for our planet.

Let's start today and build a sustainable future!

## Sectioned Prompt

User:

**\*\*Task:\*\***

Write an article

**\*\*Context Section:\*\***

Topic: Climate Change

Target Audience: High School Students

Purpose: Educational Article

**\*\*Content Requirements:\*\***

- Explanation of basic concepts related to climate change.
- Examples of current impacts on ecosystems and human populations.
- Suggestions for individual actions to mitigate climate change.

**\*\*Tone and Style:\*\***

- Informative and engaging
- Use simple language
- Include statistics and real-world examples

Assistant:

# Understanding Climate Change: A Guide for High School Students

## ## Introduction

Climate change is one of the most pressing issues of our time. It affects our planet, our ecosystems, and our daily lives. Understanding what climate change is and how it impacts us can help us take action to make a difference. This article will explain the basic concepts of climate change, provide examples of its current impacts, and suggest actions you can take to help mitigate it.

## ## What is Climate Change?

**Climate change** refers to long-term changes in global temperatures and weather patterns. These changes are primarily caused by human activities, especially the burning of fossil fuels like coal, oil, and natural gas. When we burn these fuels, we release large amounts of greenhouse gases, such as carbon dioxide (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.

## Dar ênfase às seções do prompt

Os modelos do Amazon Nova 2 podem prestar atenção a partes específicas no prompt formatando as instruções em seções e, então, fazendo referência a essas seções específicas. O modelo é capaz de ficar atento se os prompts têm uma delimitação de seções clara usando markdown, XML ou outra estrutura. Por exemplo, você pode definir o nome da seção, usar `##Section Name##` e depois se referir a essa seção em seu prompt com `##Section Name##`.

Você também pode usar essa estratégia para restringir o modelo de revelar partes do prompt de entrada na resposta gerada. Por exemplo, ao fornecer instruções ou exemplos few-shot no prompt de entrada, use delimitadores como `##Instructions##` ou `##Examples##` com um separador de nova linha e forneça instruções fortes como `DO NOT mention anything inside the ##Instructions## or ##Examples## in the response` para que o modelo não regurgite o conteúdo do prompt de entrada dessas seções em sua saída.

Exemplo: delimitação de seções

Usuário:

```
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##
```

## Usar o perfil do sistema

O perfil do sistema é um perfil no qual você pode fornecer instruções ao modelo que definem como ele responderá aos usuários finais da sua aplicação. Por exemplo, o perfil do sistema pode orientar o modelo a responder com uma determinada persona, definir conteúdo permitido e não permitido, gerar saída em um formato específico, especificar barreiras de proteção etc. As instruções no perfil do sistema, chamadas de prompt do sistema, substituirão outras instruções fornecidas nos prompts individuais do usuário e serão mantidas em todos os turnos do usuário.

### Especificar o perfil do sistema com a API

Para atribuir ao modelo um perfil personalizado, você pode definir o parâmetro `system` na API, conforme abaixo:

```
{
 "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

- Para melhor utilizar o perfil do sistema, certifique-se de que o prompt do sistema seja claro, conciso e específico, seguindo as mesmas estratégias descritas em [Criar prompts precisos](#). Por exemplo, quando você quiser restringir os tópicos aos quais o modelo deve responder, instrua-o especificamente, como “NÃO fale sobre...” ou “Você DEVE falar sobre...”.
- Para restringir ainda mais o modelo a uma estrutura hierárquica, você pode adicionar o seguinte sufixo ao prompt do sistema para enfatizar a estrutura de aderência hierárquica entre as instruções do sistema e as do usuário:

```
"\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"
```

Os seguintes itens são alguns elementos que você pode adicionar em um modelo de prompt do 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""{persona}
{model_instructions}
{response_schema}
{guardrails}
""
```

Para fornecer ao prompt do sistema a estrutura de aderência hierárquica entre as instruções do sistema e do usuário, você pode adicionar o seguinte:

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.

Exemplo 1: fornecer dicas específicas de linguagem

Depois de adicionar o prompt do sistema, as respostas dos modelos são altamente estilizadas de acordo com o estilo de um pergaminho medieval, conforme indicado no prompt do sistema.

Without a System Prompt

Sistema:

NA

Usuário:

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 uproom 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.

**Usuário:**

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.

## Exemplo 2: fornecer barreiras de proteção

Com a adição do prompt do sistema, os usuários podem adicionar barreiras de proteção para suas aplicações a fim de protegê-las contra qualquer uso não intencional. Confira abaixo dois exemplos de como as barreiras de proteção podem focar o modelo na tarefa desejada.

### Without a System Prompt

Sistema:

NA

Usuário:

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

Usuário:

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.

## Fornecer exemplos (criação de prompts few-shot)

Ao incluir alguns exemplos de sua tarefa no prompt, você pode criar um modelo estruturado para o Amazon Nova 2 seguir. Isso reduz a ambiguidade e melhora a precisão e a qualidade da saída. A técnica de fornecer exemplos claros para tornar as respostas do modelo mais alinhadas com o resultado desejado é denominada criação de prompts few-shot.

O conceito de criação de prompts few-shot é fornecer ao modelo de linguagem alguns exemplos da tarefa, junto com o formato de entrada e saída, e depois solicitar que ele gere a saída para uma nova entrada com base nos exemplos fornecidos. Esse método também ajuda a esclarecer instruções ou tarefas complexas, tornando mais fácil para o Amazon Nova 2 entender e interpretar o que está sendo solicitado.

Como adicionar exemplos à ajuda do prompt:

Adicionar exemplos pode ajudar o modelo a produzir

- Respostas consistentes que são uniformes ao estilo dos exemplos
- Respostas mais eficientes devido ao fato de reduzir a possibilidade de interpretar incorretamente as instruções e à minimização das alucinações

O quanto a performance do modelo vai melhorar usando prompts few-shot dependerá da qualidade e da diversidade dos exemplos escolhidos. Os itens abaixo demonstram as características de boas capturas no prompt:

- **Selecione exemplos diversos:** os exemplos escolhidos devem representar a distribuição de sua entrada/saída esperada em termos de diversidade (desde casos de uso comuns até casos extremos) para abranger adequadamente os casos de uso relevantes. É importante evitar qualquer viés em seus exemplos, pois o viés nas entradas também pode fazer com que as saídas sejam tendenciosas.
- **Combine os níveis de complexidade:** a complexidade dos exemplos fornecidos deve estar alinhada com o cenário ou a tarefa-alvo. É importante garantir que o grau de complexidade seja mapeado entre a entrada esperada e o exemplo escolhido no prompt.
- **Garanta a relevância:** os exemplos selecionados devem ser diretamente relevantes para o problema ou o objetivo em questão. Isso garante consistência e uniformidade nas respostas.

#### Tip

Se as sugestões acima não funcionarem, recomendamos que você crie um sistema baseado em RAG que aumente o prompt com uma seleção dinâmica de capturas com base nas semelhanças entre a consulta de entrada do usuário e um conjunto de capturas disponível.

## Exemplo 1: fornecer exemplos no prompt do usuário

Aqui, seu usuário está tentando classificar os tíquetes de suporte ao cliente recebidos em categorias predefinidas. Você pode fornecer aos modelos do Amazon Nova 2 alguns exemplos de tíquetes que são classificados corretamente para melhorar sua compreensão das categorias e do idioma usado nos tíquetes. Os exemplares devem ser concisos e representar todas as tarefas específicas em sua aplicação. Se houver um nome de campo específico que seja significativo para as tarefas, como **Ticket** ou **Category** neste exemplo, seu usuário poderá usar esses campos diretamente seguidos por dois pontos ":".

### 0-shot prompt

Usuário:

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

Usuário:

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.

## Exemplo 2: fornecer exemplos como prompt de turnos

Neste exemplo, os exemplares são fornecidos como turnos, um turno por exemplar, em que o perfil de User contém a entrada e o perfil de Assistant contém a saída esperada para o exemplar.

### 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

Usuário:

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

Usuário:

I love to eat pizza.

Assistente:

Food

Usuário:

I enjoy watching movies.

Assistente:

Entertainment

Usuário:

I am going to the gym after this.

Assistente:

Health

Usuário:

I have 20\$ in my pocket.

Assistente:

Wealth

### Exemplo 3: fornecer exemplos no prompt do sistema

Neste exemplo, você pode especificar uma seção “Exemplo” e depois enumerar uma série de exemplos no prompt do sistema. Essa forma de fornecer exemplares no prompt é especialmente útil quando seus exemplares são longos e complexos e ajuda o modelo a localizar capturas de exemplo.

### 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.

Usuário:

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>

```
Project Update Report

<i>Date:</i> February 20, 2023

<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]
```

Usuário:

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.
- Executed the initial data migration from the legacy system to the new ERP system, resulting in a 95% accuracy rate.

**Future Plans:**

- Roll out the new ERP system to all departments in the next two phases.
- Schedule and conduct follow-up training sessions for all employees.
- Implement the remaining modules of the ERP system, including financial management and human resources.
- Establish a robust monitoring and support framework to ensure smooth system operation and address any issues promptly.

**Prepared by:**

[Your Name]

[Your Position]

[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.

## Sistemas de chamada de ferramentas

A chamada de ferramentas está disponível para os modelos do Amazon Nova ao passar um esquema de configuração da ferramenta em sua solicitação. O prompt do modelo será aumentado com essa configuração de ferramenta, portanto, é um local altamente impactante para começar a otimizar seu sistema de chamada de ferramentas.

Considere estes princípios fundamentais:

- As definições das ferramentas devem ser claras e concisas. Elas devem ser fáceis de entender e a intenção deve estar extremamente aparente.

- Use os principais diferenciais e condições básicas para definir quando uma ferramenta deve ser usada em detrimento de outra.
- Seja crítico em relação aos tipos de argumentos de entrada. Pergunte-se: eles fazem sentido e seriam usados dessa forma normalmente?

Usar “Escolha de ferramenta” para controlar quando uma ferramenta é chamada

O parâmetro de escolha da ferramenta permite que você personalize o comportamento da chamada de ferramentas com o modelo. Recomendamos utilizá-lo para um controle refinado sobre quais ferramentas são chamadas e quando.

Por exemplo, para casos de uso como saída estruturada, você pode querer que uma ferramenta específica seja chamada sempre que o Amazon Nova for invocado. Você pode definir o esquema de sua saída como a ferramenta e, em seguida, definir a escolha da ferramenta com o nome dela.

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

Para muitos casos de uso agênticos, talvez você queira garantir que o modelo sempre selecione uma das ferramentas disponíveis. Para fazer isso, você pode definir a escolha da ferramenta como any, que chamará exatamente uma ferramenta sempre que o modelo for invocado.

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

Por fim, para casos de uso em que a chamada de uma ferramenta é altamente dependente do contexto da conversa, você pode definir a escolha da ferramenta como auto. Este é o comportamento padrão e deixará a seleção da ferramenta totalmente a critério do modelo.

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

```
}
}
```

## Técnicas avançadas de geração de prompts

Essas seções fornecem orientação avançada sobre como melhorar a qualidade de seus prompts e aproveitar os principais recursos, como o pensamento estendido.

### Usar o modo de raciocínio

Os modelos do Amazon Nova 2 oferecem um modo de raciocínio opcional que aprimora a abordagem do modelo para a resolução de problemas complexos, permitindo que ele resolva os problemas sistematicamente antes de responder. Aproveitar o modo de raciocínio do modelo é um recurso eficaz de melhorar a precisão de seus prompts.

Quando usá-lo: o modo de raciocínio é recomendado para tarefas complexas, como casos de uso com:

- Várias etapas de raciocínio: provas matemáticas, design de algoritmos, arquitetura do sistema
- Informações de referência cruzada: análise de documentos, comparação de opções, avaliação de compensações
- Cálculos suscetíveis a erros: modelagem financeira, análise de dados, depuração complexa
- Planejamento com restrições: otimização de recursos, gerenciamento de dependências, avaliação de riscos
- Classificações complexas: categorização de vários rótulos, taxonomias hierárquicas, limites de decisão refinados
- Cenários de chamada de ferramentas: fluxos de trabalho de API em várias etapas, otimização de consultas de banco de dados, integrações coordenadas de sistemas

#### Note

Para obter mais informações sobre o modo de raciocínio, consulte [Uso do raciocínio](#).

### Adotar uma abordagem de cima para baixo (top-down)

Para situações em que o modelo precisa avaliar várias abordagens para resolver o problema, instrua-o a adotar uma abordagem de cima para baixo.

- Os modelos do Amazon Nova 2 têm melhor desempenho quando o modelo começa com uma visão macro e depois a decompõe em subproblemas ou etapas menores e mais detalhadas.
- Direcione explicitamente o modelo para primeiro identificar o objetivo principal e, em seguida, decompô-lo em componentes gerenciáveis antes de analisar os detalhes de cada parte.
- Essa abordagem estruturada ajuda o modelo a organizar seu pensamento e a gerar encadeamentos de raciocínio mais coerentes.

Exemplo:

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

### Direcionar o encadeamento de raciocínio

Embora o modo de raciocínio forneça maior precisão por meio da solução sistemática de problemas, há cenários específicos em que o uso de prompts de encadeamento de raciocínio (CoT) no modo sem raciocínio pode atender melhor às suas necessidades.

Quando usar:

- **Transparência e auditabilidade:** quando você deseja ver, verificar ou auditar o processo de raciocínio do modelo, o CoT fornece visibilidade total de cada etapa. Isso é fundamental para setores regulamentados, decisões de alto risco ou quando você deseja documentar a lógica por trás de uma resposta.
- **Estruturas de raciocínio personalizadas:** use o CoT para aplicar padrões ou metodologias de raciocínio específicos. Você pode orientar o modelo para seguir as estruturas de decisão da sua organização, usar abordagens de solução de problemas específicas do domínio ou garantir que os fatores sejam considerados em uma ordem específica.
- **Desenvolvimento e depuração de prompts:** durante a fase de engenharia de prompts, o CoT ajuda você a entender como o modelo aborda os problemas, a identificar onde o raciocínio falha e a iterar seus prompts com mais eficiência.
- **Abordagens híbridas:** considere usar o CoT durante o desenvolvimento para aperfeiçoar seus prompts e, em seguida, migrar para o modo de raciocínio na implantação em produção assim que houver confiança na abordagem do modelo para o seu caso de uso específico.



 Note

Nem todas as tarefas exigem o CoT. Para tarefas mais simples, permita que o modelo use seu próprio processo de raciocínio.

### Direcionamento do CoT do modelo:

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

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

### Usar janelas de contexto longo

Os modelos do Amazon Nova 2 possuem suporte para um tamanho de contexto de 1 milhão de tokens e apresentam excelente desempenho na compreensão de código e em respostas a perguntas sobre documentos extensos. O desempenho (incluindo a adesão aos prompts do sistema e o uso de ferramentas) pode apresentar um pequeno declínio conforme o tamanho do contexto aumenta.

### Como usar:

- Coloque dados longos no início: posicione seus documentos e entradas longos próximo do início do seu prompt. Coloque-os antes da sua consulta, instruções e exemplos.
- Coloque as instruções no final: posicione suas instruções no final do prompt. O modelo tem melhor desempenho quando o contexto é fornecido primeiro e as instruções são fornecidas no final.
- Estructure marcadores de início e fim do conteúdo do documento: use marcadores de início e fim, como `DOCUMENT {idx} START` e `DOCUMENT {idx} END`, para indicar o início e o fim de um documento longo, em que {idx} representa o índice do documento específico.

### Exemplo de modelo:

```
// 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
```

## Fundamentar as respostas no texto de apoio

Recomendamos que você forneça ao modelo informações confiáveis relevantes para a consulta de entrada. Essas informações, junto com a consulta de entrada, geralmente fazem parte do sistema denominado geração aumentada via recuperação (RAG).

- Nesse processo, alguns documentos ou informações relevantes e contextuais são acrescentados ao prompt real do usuário para que o modelo obtenha conteúdo confiável para gerar uma resposta relevante e precisa.
- Instruir o Amazon Nova 2 a responder usando um texto de referência de uma fonte confiável pode orientá-lo a compor sua resposta com base no material fornecido e garantir que sua resposta seja fundamentada em informações precisas e relevantes, aumentando a confiabilidade e a credibilidade do conteúdo gerado.
- Além disso, usar um texto de referência pode ajudar a evitar alucinações, melhorando assim a qualidade geral e a confiabilidade das respostas. Para minimizar a alucinação, recomendamos mencionar **DO NOT USE INFORMATION THAT IS NOT IN REFERENCE TEXTS!** explicitamente nas instruções do modelo.

## Modelo de 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}
```

Exemplo: fornecer um contexto de ancoragem ajuda a evitar que o modelo tenha alucinações

Este exemplo mostra como o contexto de ancoragem pode impedir que o modelo tenha alucinações.

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!
```

Usuário:

```
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.
```

Fundamentar usando marcadores de citação

Para tarefas de documentos longos, recomendamos que você instrua o modelo do Amazon Nova 2 a fundamentar suas respostas usando as citações das seções relevantes dos documentos antes de prosseguir com a tarefa.

Essa abordagem ajuda o modelo a se concentrar nas informações mais pertinentes e evitar se distrair com conteúdo irrelevante. Quando você solicita que o modelo fundamente sua resposta, as seções que podem ser citadas devem ser numeradas. Como, por exemplo, Passage %[1]%, Passage %[2]% e assim por diante.

## Exemplos: uso de marcadores de citação

### Example Prompt de marcadores de citação

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)  
...

Depois de extrair as principais informações com base na tarefa do usuário, você pode usar as métricas financeiras extraídas para responder às perguntas relevantes, conforme mostrado:

### Example Análise de acompanhamento com métricas extraídas

## 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

## Usar a Ancoragem na Web do Nova

Em vez de gerar prompts diretamente de citações para ancorar o modelo no texto de apoio, os modelos do Amazon Nova 2 fornecem uma ferramenta interna de ancoragem na web que pode ser usada. Quando habilitados, os modelos do Amazon Nova 2 consultarão diretamente a web e os gráficos de conhecimento da Amazon e fundamentarão a resposta final com citações.

Para saber mais sobre como aproveitar a Ancoragem na Web do Amazon Nova, você pode consultar o [guia do usuário da Ancoragem na Web do Amazon Nova](#).

## Gerar saída estruturada

Para garantir formatos de saída consistentes e estruturados, você pode usar saídas estruturadas, incluindo formatos como XML, JSON ou Markdown, ou utilizando a funcionalidade de uso de ferramentas.

- Essa abordagem permite que os sistemas downstream compreendam e processem de forma mais eficaz as saídas geradas pelo modelo.
- Ao fornecer instruções explícitas ao modelo, as respostas são geradas de forma que sigam um esquema predefinido.

Por exemplo, se o analisador downstream exigir convenções de nomenclatura específicas para as chaves em um objeto JSON, você deverá especificar o esquema de resposta ao final do prompt. Além disso, se você preferir que as respostas estejam no formato JSON sem nenhum texto de preâmbulo, instrua o modelo adequadamente. Ou seja, instrua de forma explícita: Gere somente a saída JSON. NÃO forneça nenhum preâmbulo. para garantir uma saída limpa.

#### Tip

- Observamos a melhor aderência aos requisitos de formato de dados quando eles são definidos no próprio esquema, em vez de por meio do uso de exemplares (como a especificação de datas no formato AAAA/MM/DD).
- Para saídas JSON simples com até dez chaves, você pode encontrar o esquema abaixo. Para esquemas mais complexos, recomendamos que você defina seu esquema por meio de uma ferramenta. O uso da ferramenta utiliza uma técnica chamada decodificação restrita, que aumentará a aderência do modelo a esses esquemas complexos.

## Esquemas comuns de formatação

Confira a seguir alguns exemplos de esquemas comuns de formatação.

### 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 )

"""
```

Pré-preencher o conteúdo do assistente

Se você estiver produzindo uma saída estruturada no modo sem raciocínio, poderá induzir a resposta do modelo ao pré-preencher o conteúdo do assistente.

O pré-preenchimento melhora a consistência no formato de saída no modo sem raciocínio. Essa técnica permite direcionar as ações do modelo, ignorar preâmbulos e aplicar formatos de saída específicos, como JSON e XML. Por exemplo, se você pré-preencher o conteúdo do assistente com { ou ````json, essa entrada orientará o modelo a gerar o objeto JSON sem fornecer informações adicionais.

Tip

Se você está buscando especificamente extrair JSON, um padrão comum é pré-preenchê-lo com ````json e adicionar uma sequência de parada em ````. Isso garante que o modelo gere um objeto JSON que pode ser analisado de forma programática.

Exemplo Pré-preencher o conteúdo do assistente

O seguinte código demonstra como pré-preencher com a 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())
```

Especificar uma ferramenta a ser usada em esquemas complexos

Outra abordagem é usar ferramentas para aplicar um esquema específico na resposta do modelo, incluindo o esquema JSON do Pydantic na seção do esquema de uso de ferramentas. Você pode especificar a escolha da ferramenta para o esquema fornecido e a resposta do Amazon Nova será estruturada com base na ferramenta selecionada. Para saber mais sobre como aproveitar o uso de ferramentas, consulte [Uso de ferramentas](#).

Exemplos

Exemplo 1: adicionar um esquema de saída

Adicionar a seção Esquema de saída com o esquema apropriado faz com que o modelo prefira se ajustar a esse esquema. No entanto, a saída do modelo não é determinística e pode variar em relação ao esquema de saída.

Unspecific Prompt

Usuário:

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

Usuário:

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."
}
]
```

Exemplo 2: pré-preencher a resposta do modelo

Outra abordagem é pré-preencher a resposta do modelo incluindo o texto inicial desejado na mensagem do assistente. Nesse caso, a resposta do modelo do Amazon Nova continuará de onde a mensagem do assistente parou.

Dica: o pré-preenchimento só é válido quando o raciocínio não está habilitado.

Usuário:

```
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 (pré-preenchimento):

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

Exemplo 3: especificar uma ferramenta a ser usada

Como alternativa ao uso da técnica de pré-preenchimento para uma saída estruturada, você pode combinar a funcionalidade da ferramenta do Nova com a toolChoice. Neste exemplo, o modelo vai gerar uma chamada de ferramenta que adere ao esquema JSON fornecido e chamará a ferramenta específica para o formato JSON completo definido. Para obter orientação adicional, consulte [Sistemas avançados](#).

Usuário:

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"
    }
}
}
}

```

Casos de uso multilíngues

Os modelos do Amazon Nova 2 foram treinados em mais de 200 idiomas e otimizados para 15 idiomas.

Tópicos

- [Prompts para traduções precisas](#)
- [Aplicar convenções de escrita consistentes](#)

Prompts para traduções precisas

Para aproveitar esse recurso para traduções curtas (poucas frases), você pode instruir o modelo a traduzir o texto para o idioma de destino especificado.

Example Prompts de tradução

```
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}
```

Aplicar convenções de escrita consistentes

Em linguagens baseadas em caracteres, os modelos do Amazon Nova 2 podem utilizar o conjunto de caracteres do idioma de origem. Você pode usar o prompt a seguir para impor uma saída consistente.

Example Aplicar convenções de escrita

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

Chamada de ferramentas

Sistemas agênticos

Tópicos

- [Definir os parâmetros de inferência corretos](#)
- [Considerar requisitos de latência](#)
- [Use palavras intencionais para as instruções de chamadas de ferramentas](#)
- [Aproveitar os comandos de “pensamento”](#)
- [Ordenação de chamadas de ferramentas](#)
- [Criar esquemas de ferramentas de qualidade](#)
- [Criar subagentes](#)

- [Usar ferramentas para entradas multimodais](#)
- [Próximas etapas](#)

Definir os parâmetros de inferência corretos

A chamada de ferramentas requer uma saída estruturada muito específica do modelo e é aprimorada com o uso dos seguintes parâmetros de inferência:

- Modo sem raciocínio: temperature: 0.7 e Top P: 0.9
- Modo de raciocínio: temperature: 1 e Top P: 0.9

Considerar requisitos de latência

 Tip

Os modelos do Amazon Nova 2 são capazes de chamar ferramentas com o raciocínio ligado e desligado. No entanto, os modos de raciocínio têm um impacto significativo na latência.

Para aplicações sensíveis à latência, você deve otimizar o modo de raciocínio desligado e simplificar as chamadas de ferramentas necessárias sempre que possível. Divida os fluxos de trabalho de várias etapas em etapas distintas para reduzir a dependência do modelo em repetir parâmetros desnecessários.

Use palavras intencionais para as instruções de chamadas de ferramentas

Nomes de ferramentas: referenciar ferramentas no prompt do sistema é comum em sistemas de chamada de ferramentas para instruir o modelo sobre quando chamar uma ferramenta. Ao referenciar ferramentas no prompt, recomendamos que você use o nome da ferramenta em vez de referências ou exemplos em xml ou no estilo Python.

Exemplo de uma boa referência de ferramenta

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

Exemplo de uma referência de ferramenta ruim

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

Aproveitar os comandos de “pensamento”

Para todos os casos de uso em que o pensamento é benéfico para a chamada de ferramentas, recomendamos que você use o modo de raciocínio em vez de fornecer prompts para que o modelo “pense em tags” ou use uma ferramenta de “pensamento”.

Os modelos do Amazon Nova 2 são treinados extensivamente para o modo de raciocínio e produzirão os melhores resultados quando usados no modo de raciocínio para o encadeamento de pensamento.

Ordenação de chamadas de ferramentas

Em casos de uso que podem exigir o uso simultâneo de chamadas de ferramentas nativas e ferramentas integradas, o modelo tende a chamar primeiro as ferramentas integradas.

Não instrua o modelo a agir de forma diferente no prompt. Em vez disso, projete seu fluxo de trabalho para levar isso em consideração.

Por exemplo, se você não quiser que o modelo use ferramentas integradas, não as inclua em seu fluxo de trabalho para que o modelo não seja tendencioso.

Criar esquemas de ferramentas de qualidade

Os esquemas de ferramentas são um dos principais locais em que você pode aplicar engenharia de prompts para criar sistemas eficazes de chamada de ferramentas. No entanto, é importante considerar o que é capturado no próprio esquema da ferramenta, como cada elemento do esquema é descrito semanticamente e como o prompt do sistema faz referência às ferramentas e aos elementos do esquema nas instruções do sistema.

Os modelos do Amazon Nova 2 são otimizados para descrições concisas nos esquemas da ferramenta. Seja breve.

Esquema de ferramentas versus diretrizes de prompts do sistema:

Incluir no esquema da ferramenta:

- Funcionalidade principal: o que a ferramenta faz (recomenda-se de 20 a 50 palavras)
- Especificações dos parâmetros: descrições claras de cada parâmetro (cerca de dez palavras por parâmetro)
- Formatos esperados: tipos de dados (como enum, int, float), campos obrigatórios e intervalos de valores válidos

Incluir no prompt do sistema:

- Dedique uma seção `#Tool Usage` à lógica de orquestração (quando e por que usar ferramentas específicas) e regras de negócios (lógica condicional, requisitos de sequenciamento e dependências).
- Estratégias de tratamento de erros: adicione uma seção `#Error Handling and Troubleshooting` com instruções sobre como responder a falhas ou resultados inesperados
- Formatação de saída: adicione detalhes sobre como apresentar ao usuário

Exemplo

```
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>
```

Criar subagentes

Considere criar subagentes especializados em vez de um único agente com muitas ferramentas ao encontrar:

- Contagem de ferramentas excede 20: grandes conjuntos de ferramentas se tornam difíceis de gerenciar e aumentam os erros de seleção
- Domínios funcionais distintos: as ferramentas naturalmente se agrupam em categorias separadas (como recuperação de dados versus processamento versus relatórios)
- Esquemas complexos: quando a profundidade dos parâmetros excede de 3 a 4 níveis ou as ferramentas têm interdependências complexas
- Duração da conversa: os fluxos de trabalho geralmente excedem de 15 a 20 turnos e podem se beneficiar de subagentes especializados
- Degradação do desempenho: se você observar uma diminuição da precisão na seleção de ferramentas ou um aumento da latência

Tip

Os servidores MCP vêm com ferramentas e esquemas que você não pode controlar. Inclua somente as ferramentas necessárias para que seu fluxo de trabalho conclua a tarefa necessária.

Usar ferramentas para entradas multimodais

Para tarefas multimodais, não observamos uma maior precisão aproveitando ferramentas para tarefas estruturadas (como extração ou geração de carimbo de data e hora).

Em vez disso, recomendamos que você revise as seções relevantes na seção Gerar prompts para entradas multimodais para saber como gerar prompts com sucesso para o modelo usando os modelos fornecidos.

Próximas etapas

- Para gerar prompts multimodais, consulte [Gerar prompts para entradas multimodais](#).

Gerar prompts para entradas multimodais

As seções a seguir fornecem orientação para a compreensão de imagens e vídeos. Para gerar prompts relacionados a áudio, consulte a seção [the section called “Prompts de conversa por voz”](#).

Diretrizes gerais de multimodais

Prompts do usuário e do sistema

Para entender casos de uso multimodais, cada solicitação deve incluir um texto de prompt do usuário. Os prompts do sistema, que só podem conter texto, são opcionais.

Os prompts do sistema podem ser usados para especificar uma persona para o modelo e definir a personalidade geral e o estilo de resposta, mas não devem ser usados para uma definição detalhada de tarefas ou instruções de formatação de saída.

Inclua a definição, as instruções e os detalhes de formatação da tarefa no prompt do usuário para ter um efeito mais forte do que o prompt do sistema para casos de uso multimodais.

Ordem de conteúdo

Uma solicitação de compreensão multimodal enviada ao Amazon Nova deve conter um ou mais arquivos e um prompt do usuário. O prompt de texto do usuário deve ser o último item da mensagem, sempre depois do conteúdo da imagem, do documento ou do vídeo.

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

Nos casos em que você quiser se referir a arquivos específicos do prompt do usuário, use elementos de “texto” para definir rótulos que precedam cada bloco de arquivos.

```
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>" }
]
```

Compreensão de documentos e imagens

As seções a seguir fornecem orientação sobre como criar prompts para tarefas que exigem a compreensão ou a análise de imagens e documentos.

Extração de texto de imagens

Os modelos do Amazon Nova podem extrair texto de imagens, um recurso conhecido como reconhecimento óptico de caracteres (OCR). Para obter melhores resultados, certifique-se de que a entrada de imagem fornecida ao modelo tenha uma resolução alta o suficiente para que os caracteres do texto sejam fáceis de discernir.

Para casos de uso de extração de texto, recomendamos a seguinte configuração de inferência:

- temperature: padrão (0.7)
- topP: padrão (0,9)
- Não habilite o raciocínio

Os modelos do Amazon Nova podem extrair texto no formato Markdown, HTML ou LaTeX. O seguinte modelo de prompt de usuário é recomendado:

```
## 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 `<img>` in the output.
4. NEVER use Markdown image tags `![]()` in the output.
```

5. Always wrap the entire output in ``` tags.

A saída é envolvida por blocos de código Markdown completos ou parciais (```). Você pode remover os blocos de código usando um código semelhante ao seguinte:

```
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()
```

Extração de informações estruturadas de imagens ou texto

Os modelos do Amazon Nova podem extrair informações de imagens no formato JSON analisável por máquina, um processo conhecido como extração de informações chave (KIE). Para realizar o KIE, forneça o seguinte:

- Um esquema JSON. Uma definição formal de esquema que segue a especificação do esquema JSON.
- Um ou mais dos seguintes: um arquivo de documento ou texto de documento ou imagem

O documento ou a imagem sempre deve ser incluído antes que o usuário gere o prompt na solicitação.

Para casos de uso do KIE, recomendamos a seguinte configuração de inferência:

- temperature: 0
- Raciocínio: o raciocínio não é obrigatório, mas pode melhorar os resultados quando entradas somente de imagem ou esquemas complexos são usados.

Modelos de prompt

Entrada somente de documento ou imagem

```
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}
```

Entrada somente de texto

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}
```

Entrada de documento ou imagem e texto

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}
```


Detecção de objetos e suas posições nas imagens

Os modelos do Amazon Nova 2 oferecem a capacidade de identificar objetos e suas posições nas imagens, uma tarefa às vezes chamada de ancoragem da imagem ou localização de objetos. As aplicações práticas incluem análise e marcação de imagens, automação da interface do usuário, edição de imagens e outras.

Independentemente da resolução da entrada da imagem e da proporção, o modelo usa um espaço de coordenadas que divide a imagem em mil unidades horizontalmente e mil unidades verticalmente, com a localização x:0 y:0 no canto superior esquerdo da imagem.

As caixas delimitadoras são descritas usando o formato [x1, y1, x2, y2] que representa esquerda, superior, direita e inferior, respectivamente. As coordenadas bidimensionais são representadas usando o formato [x, y].

Para casos de uso de detecção de objetos, recomendamos os seguintes valores de parâmetros de inferência:

- temperature: 0
- Não habilite o raciocínio

Modelos de prompt: detecção geral de objetos

Recomendamos os modelos de prompt de usuário a seguir.

Detecção de várias instâncias com caixas delimitadoras:

```
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.
```

Detecção de uma única região com caixa delimitadora:

```
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.
```

Detecção de várias instâncias com pontos centrais:

```
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.
```

Detecção de uma única região com ponto central:

```
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.
```

Análise da saída do modelo:

Cada um dos prompts recomendados acima produzirá uma sequência de caracteres separada por vírgula contendo uma ou mais descrições de caixas delimitadoras em um formato semelhante ao seguinte: Pode haver uma pequena variação no fato de um “.” estar incluído no final da string. Por exemplo, ., [356, 770, 393, 872], [626, 770, 659, 878].

Você pode analisar as informações de coordenadas geradas pelo modelo usando uma expressão regular, conforme mostrado no exemplo de código Python a seguir.

Exemplo de código

```
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"\s*([^\s\[\]]*?)\s*"
    return [
        tuple(int(x.strip()) for x in match.split(","))
        for match in re.findall(pattern, text)
    ]
```

Exemplo de código

Para remapear as coordenadas normalizadas de uma caixa delimitadora para o espaço de coordenadas da imagem de entrada, você pode usar uma função semelhante ao exemplo de Python a seguir.

```
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,  
]
```

Modelos de prompt: detecção de várias classes de objetos com posições

Quando quiser identificar várias classes de itens em uma imagem, você pode incluir uma lista de classes em seu prompt usando uma das abordagens de formatação a seguir.

Para classes amplamente conhecidas que o modelo provavelmente compreende bem, liste os nomes das classes (sem aspas) entre colchetes:

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

Para classes com nuances, incomuns ou provenientes de domínios especializados com os quais o modelo talvez não esteja familiarizado, inclua uma definição para cada classe entre parênteses. Como essa tarefa é desafiadora, espera-se que o desempenho do modelo sofra degradação.

```
[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)]
```

Use um dos modelos de prompt de usuário a seguir, dependendo do formato de saída JSON de sua preferência.

Opção de 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]
  },
  ...
]
```

Opção de 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]
  },
  ...
]
```

Opção de 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], ...],
  ...
}
```

Opção de 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], ...]
  },
  ...
]
```

Análise da saída do modelo

A saída será codificada como um JSON que pode ser analisado com qualquer biblioteca de análise JSON.

Modelos de prompt: detecção de limites de interface do usuário em capturas de tela

Recomendamos os modelos de prompt de usuário a seguir.

Detecção da posição do elemento da interface do usuário com base em uma meta:

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.

Detecção da posição do elemento da interface do usuário com base no texto:

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.

Análise da saída do modelo:

Para cada um dos prompts de detecção de limites da interface do usuário acima, você pode analisar as informações de coordenadas geradas pelo modelo usando uma expressão regular, conforme mostrado no exemplo de código Python abaixo.

Exemplo de código

```
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)
    ]
```

Compreensão de vídeos

As seções a seguir fornecem orientação sobre como criar prompts para tarefas que exigem a compreensão ou a análise de vídeos.

Resumo de vídeos

Os modelos do Amazon Nova podem gerar resumos de conteúdo de vídeos.

Para casos de uso de resumo de vídeo, recomendamos os seguintes valores de parâmetros de inferência:

- temperature: 0
- Alguns casos de uso podem se beneficiar da habilitação do raciocínio do modelo

Nenhum modelo específico de geração de prompts é necessário. Seu prompt de usuário deve especificar claramente os aspectos do vídeo que lhe interessam. Confira alguns exemplos de prompts eficazes:

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?

Geração de legendas detalhadas para vídeos

Os modelos do Amazon Nova podem gerar legendas detalhadas para vídeos, uma tarefa referida como legendagem densa.

Para casos de uso de legendas de vídeo, recomendamos os seguintes valores de parâmetro de inferência:

- temperature: 0
- Alguns casos de uso podem se beneficiar da habilitação do raciocínio do modelo

Nenhum modelo específico de geração de prompts é necessário. Seu prompt de usuário deve especificar claramente os aspectos do vídeo que lhe interessam. Confira alguns exemplos de prompts eficazes:

```
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.
```

Análise de filmagens de vídeo de segurança

Os modelos da Amazon Nova podem detectar eventos em filmagens de segurança.

Para casos de uso de filmagens de segurança, recomendamos os seguintes valores de parâmetros de inferência:

- temperature: 0
- Alguns casos de uso podem se beneficiar da habilitação do raciocínio do modelo

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.

Extração de eventos de vídeo com carimbos de data e hora

Os modelos do Amazon Nova podem identificar carimbos de data e hora relacionados a eventos em um vídeo. Você pode solicitar que os carimbos de data e hora sejam formatados em segundos ou no formato MM:SS. Por exemplo, um evento que ocorre em 1 minuto e 25 segundos no vídeo pode ser representado como 85 ou 01:25.

Para esse caso de uso, recomendamos os seguintes valores de parâmetros de inferência:

- temperature: 0
- Não use o raciocínio

Recomendamos que você use prompts como os abaixo:

Identificação da hora de início e término de um 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]]

Identificação de várias ocorrências de um 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]]

Geração de um log de segmentos de vídeo com carimbos de data e hora

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.

Classificação de vídeos

Você pode usar os modelos do Amazon Nova para classificar vídeos com base em uma lista predefinida de classes que você fornece.

Para esse caso de uso, recomendamos os seguintes valores de parâmetros de inferência:

- temperature: 0
- O raciocínio não deve ser usado

Use o seguinte modelo de prompt:

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

Exemplo de:

What is the most appropriate category for this video? Select your answer from the options provided:

Arts
Technology
Sports
Education

Código e solução de problemas

Este capítulo fornece exemplos de código e orientação de solução de problemas para ajudar você a trabalhar de forma eficaz com os modelos do Amazon Nova.

Biblioteca de códigos

Esta seção fornece exemplos de código para operações comuns do Amazon Nova usando a API Converse ou a API InvokeModel.

Exemplos da API Converse

Solicitação básica

Envie uma solicitação de texto básica para modelos do Amazon Nova usando a 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)

```

Entrada multimodal usando ativo incorporado

Processe conteúdo multimodal incorporando dados de documentos, imagens, vídeos ou áudios diretamente na solicitação. Este exemplo usa dados de imagem. Para obter detalhes sobre a estrutura de conteúdo para outras modalidades, consulte os [detalhes do ContentBlock na documentação da API do 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)

```

Entrada multimodal usando o URI do S3

Processe conteúdo multimodal referenciando documentos, imagens, vídeos ou arquivos de áudio armazenados no S3. Este exemplo usa uma referência de imagem. Para obter detalhes sobre a estrutura de conteúdo para outras modalidades, consulte os [detalhes do ContentBlock na documentação da API do 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)
```

Pensamento estendido (raciocínio)

Habilite o pensamento estendido para tarefas complexas de resolução de problemas.

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

```

Ferramenta integrada: Ancoragem do Nova com citações

Use a Ancoragem do Nova para recuperar informações em tempo real da web com citações.

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)
```

Ferramenta integrada: Interpretador de Código

Use a ferramenta Interpretador de Código para executar código Python para cálculos e análise de dados.

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)

```

Uso de ferramentas

Defina ferramentas personalizadas para o modelo usar durante a conversa.

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)

```

Exemplos da API InvokeModel

Os exemplos abaixo focam as poucas áreas-chave em que as estruturas de solicitação e resposta da API Invoke diferem levemente das da API Converse. Em quase todos os outros aspectos, as duas APIs são compatíveis, então você poderá adaptar facilmente os exemplos da API Converse acima para trabalhar com a API InvokeModel.

Solicitação básica

Envie uma solicitação de texto básica para os modelos do Amazon Nova 2 usando a API InvokeModel.

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)
```

API InvokeModel com raciocínio

Use a API InvokeModel com o raciocínio habilitado para a resolução de problemas complexos.

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)
```

Solução de problemas

Esta seção fornece soluções para problemas comuns ao trabalhar com modelos do Amazon Nova.

Autenticação e configuração

Permissões ausentes

Sintomas: não é possível acessar os modelos ou recursos do Nova

Solução:

- Certifique-se de que seu perfil do IAM tenha a permissão Amazon-BedrockFullAccess ou as permissões apropriadas

- Solicite acesso a modelos específicos por meio do console do Amazon Bedrock
- Verifique as permissões para acesso ao modelo e uso da ferramenta

Acesso ao modelo negado

Sintomas: falha na solicitação de acesso ao modelo

Solução:

- Solicite acesso a modelos específicos por meio do console do Amazon Bedrock
- Verifique se sua conta possui permissão para acessar o modelo solicitado
- Confira a disponibilidade regional do modelo

Problemas de disponibilidade regional

Sintomas: recurso não disponível na região selecionada

Solução:

- A Ancoragem na Web está disponível somente nas regiões dos EUA com os perfis CRIS dos EUA
- Verifique se o modelo e os recursos estão disponíveis na região selecionada
- Mude para uma região com suporte, se necessário

Configuração de tempo limite

Sintomas: o tempo limite das solicitações é atingido antes da conclusão

Causa: tempo limite padrão muito curto para operações complexas

Solução: defina as configurações de tempo limite estendido

```
from botocore.config import Config

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

```
)  
)
```

 Note

As solicitações de inferência do Amazon Nova podem levar até 60 minutos para operações complexas.

Problemas de respostas das APIs

Compreensão dos motivos da interrupção:

`end_turn`

Conclusão normal. Nenhuma ação é necessária.

`max_tokens`

Limite de tokens atingido.

Solução: aumente o parâmetro `maxTokens` em `inferenceConfig`.

`content_filtered`

O conteúdo violou a política de IA responsável da AWS.

Solução: revise e modifique sua entrada para estar em conformidade com as políticas de conteúdo.

`malformed_model_output`

Formato de saída inválido.

Solução: verifique o esquema de saída e as restrições; verifique se o esquema JSON está formatado corretamente.

`malformed_tool_use`

Formato de chamada de ferramenta inválido.

Solução: verifique se as definições da ferramenta correspondem ao esquema esperado; verifique se os parâmetros de entrada da ferramenta estão formatados corretamente.

service_unavailable

Serviço de ferramentas integradas indisponível.

Solução: tente fazer a solicitação novamente após um breve intervalo; verifique o painel de integridade do serviço da AWS.

invalid_query

Consulta inválida para a ferramenta integrada.

Solução: revise o formato e os parâmetros da consulta; garanta que a consulta atenda aos requisitos da ferramenta.

max_tool_invocations

As novas tentativas da ferramenta se esgotaram.

Solução: simplifique a tarefa ou divida-a em etapas menores; analise as mensagens de erro da ferramenta em busca de problemas específicos.

Erros do modo de raciocínio

Respostas truncadas com alto esforço de raciocínio

Solução: para um alto esforço de raciocínio, desconfigure estes parâmetros: `temperature`, `topP`, `maxToken`. Isso permite que o modelo use configurações ideais para tarefas complexas de raciocínio.

Tokens insuficientes para o raciocínio

Erro: “`maxTokens` is insufficient”

Solução: faça uma nova tentativa automática com aumento de limite

```
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
```

Problemas de uso das ferramentas

Ocorrem falhas de validação do esquema

Erros de validação do esquema da ferramenta

Solução:

- Limite os esquemas JSON a duas camadas de aninhamento para obter o melhor desempenho
- Certifique-se de que todos os campos obrigatórios estejam definidos corretamente
- Valide o esquema em relação à especificação do esquema JSON

O modelo não está usando as ferramentas corretamente

Solução:

- Certifique-se de que o nome da ferramenta descreva claramente sua finalidade
- Forneça uma descrição detalhada da funcionalidade da ferramenta
- Defina explicitamente o esquema de entrada com descrições claras dos parâmetros
- Inclua exemplos na descrição quando for útil

Comportamento inconsistente da chamada de ferramentas

Solução: defina temperature como 0 para chamar a ferramenta:


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

Isso permite uma decodificação ágil para um uso mais confiável da ferramenta.

Conflitos de escolha de ferramentas

Problema: erro ao usar ferramentas personalizadas com pesquisa na web ou interpretador de código

Solução: não inclua um toolSpec personalizado com o nome nova_grounding, pois entra em conflito com a ferramenta do sistema. Use a configuração da ferramenta do 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", ...}
#   }]
# }
```

Problemas na ancoragem na web

Problemas de controle de acesso

Problema: a ancoragem na web e o interpretador de código não estão funcionando

Solução: garanta que sua política do IAM inclua:

```
{
  "Statement": [
    {
      "Effect": "Allow",
```

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

Problemas com a política de controle de serviços

Problema: a ancoragem na web está bloqueada pela SCP

Solução: se você tiver políticas de controle de serviços com a condição `aws:requestedRegion`, atualize-as para permitir uma região “não especificada” para a funcionalidade Ancoragem na Web.

Limitações de processamento de mídia

Compreensão ruim do conteúdo multilíngue em imagens e vídeos

Limitação: os modelos Nova têm uma compreensão limitada do conteúdo multilíngue na mídia visual

Solução:

- Forneça traduções de texto junto com imagens
- Use entradas baseadas em texto para conteúdo multilíngue sempre que possível

Identificação de pessoas

Problema: o modelo se recusa a identificar pessoas em imagens

Comportamento esperado: os modelos se recusarão a identificar ou nomear indivíduos em imagens, documentos ou vídeos por motivos de privacidade e segurança

Solução alternativa: pergunte sobre características gerais ou o contexto em vez de identidades específicas

Limitações do raciocínio espacial

Problema: análise de layout ou localização imprecisa

Limitação: recursos limitados para raciocínio espacial preciso

Solução:

- Use a detecção de caixa delimitadora para a localização de objetos
- Forneça pontos de referência claros em seus prompts
- Divida consultas espaciais complexas em componentes mais simples

Texto pequeno em imagens e vídeos

Problema: não é possível ler texto pequeno na mídia

Solução:

- Recorte imagens para focar as seções de texto relevantes
- Aumente a resolução da mídia de origem
- Forneça o texto separadamente, se disponível

Gerenciamento de documentos e arquivos

Conteúdo não compatível

Problema: falha no processamento do PDF

Causas:

- PDFs com perfis de cores CMYK
- PDFs contendo imagens SVG

Solução:

- Converta PDFs em perfil de cores RGB
- Rasterize imagens SVG antes de incluí-las em PDFs

Estimativa de tokens

Problema: uso inesperado de tokens com PDFs

Diretriz: estime aproximadamente 2.560 tokens por página PDF padrão de 8,5×11"

Solução: ajuste maxTokens adequadamente com base no tamanho do documento

Referência de APIs e SDKs

Esta seção fornece documentação de referência técnica completa para as APIs e os SDKs do Amazon Nova.

Tópicos

- [Esquema de solicitações e respostas](#)
- [Referência do SDK](#)

Esquema de solicitações e respostas

O esquema de solicitação é quase idêntico entre a API Invoke e a API Converse. A principal diferença é como os dados binários (imagens, vídeo, áudio) são codificados: a API Converse usa matrizes binárias, enquanto a API Invoke usa strings codificadas em Base64.

Estrutura completa da solicitação

A seguir, mostramos a estrutura completa de solicitação dos modelos Amazon Nova. Todos os campos são opcionais, a menos que sejam marcados como obrigatórios:

```
{
  "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"
    }
  }
}

```

Principais parâmetros de solicitação:

- **system**: prompt do sistema fornecendo contexto e instruções

- `messages`: matriz de turnos de conversa com perfil (usuário ou assistente) e conteúdo
- `inferenceConfig`: controla o comportamento de saída do modelo (`temperature`, `tokens` etc.)
- `toolConfig`: especificações da ferramenta para chamada de função

Note

Ao usar a API Converse, os parâmetros `topK` e `reasoningConfig` devem ser colocados em `additionalModelRequestFields` vez de em `inferenceConfig`.

As seguintes seções fornecem explicações detalhadas de cada parâmetro da solicitação:

operacional

`system`: (opcional) o prompt do sistema para a solicitação. Um prompt do sistema fornece contexto e instruções para o Amazon Nova, como especificar uma meta ou um perfil específico.

mensagens

`messages`: (obrigatório) a matriz de mensagens de entrada que contém turnos das conversas.

- `role`: (obrigatório): o perfil do turno da conversa. Os valores válidos são `user` e `assistant`. A primeira mensagem deve sempre usar o perfil `user`.
- `content`: (obrigatório) uma matriz de blocos de conteúdo. Cada bloco especifica um tipo de conteúdo (`text`, `image`, `video` ou `audio`):
 - `text`: o conteúdo de texto do turno da conversa. Se combinado com imagem ou vídeo, é interpretado como texto de acompanhamento.
 - `image`: (não compatível com o Nova 2 Lite) conteúdo de imagem com:
 - `format`: (obrigatório) formato da imagem: `jpeg`, `png`, `webp` ou `gif`
 - `source.bytes`: (obrigatório) Dados de imagem como matriz binária (API Converse) ou `string Base64` (API Invoke)
 - `video`: (não compatível com o Nova 2 Lite) conteúdo de vídeo com:
 - `format`: (obrigatório) formato de vídeo: `mkv`, `mov`, `mp4`, `webm`, `three_gp`, `flv`, `mpeg`, `mpg` ou `wmv`
 - `source`: (obrigatório) fonte de vídeo via URI do S3 (`s3Location.uri` e opcional `bucketOwner`) ou bytes de arquivo (`bytes`)

- **audio:** (somente o Amazon Nova Sonic) conteúdo de áudio com:
 - **format:** (obrigatório) formato de áudio: mp3, opus, wav, aac, flac, mp4, ogg ou mkv
 - **source:** (obrigatório) fonte de áudio via URI do S3 ou bytes de arquivo

inferenceConfig

inferenceConfig: (opcional) parâmetros de configuração que controlam a geração de saída do modelo.

- **maxTokens:** (opcional) o máximo de tokens a serem gerados antes de parar. Os modelos do Amazon Nova podem parar antes de atingir esse limite. O valor máximo é 5,000. Se não for especificado, usa um padrão dinâmico com base no contexto da solicitação.
- **temperature:** (opcional) randomização nas respostas. Intervalo válido: 0,00001 a 1 (padrão: 0,7). Valores mais baixos geram uma saída mais determinística.
- **topP:** (opcional) limite de amostragem de núcleo. O Amazon Nova coleta amostras de tokens cuja probabilidade cumulativa atinge topP. Intervalo válido: 0 a 1 (padrão: 0,9). Ajuste **temperature** ou **topP**, não os dois.
- **topK:** (opcional) apenas amostra dos principais tokens K. Remove respostas de baixa probabilidade. Intervalo válido: 0 a 128 (padrão: não usado).

Note

Para a API Converse, passe o parâmetro **topK** em **additionalModelRequestFields**.

- **stopSequences:** (obrigatório) matriz de strings que interrompe a geração ao ser encontrada.
- **reasoningConfig:** (somente o Amazon Nova Sonic) configuração de raciocínio:
 - **type:** (opcional) **enabled** ou **disabled** (padrão: **disabled**)
 - **maxReasoningEffort:** esforço computacional: **low**, **medium** ou **high**. Com **low** e **medium**, o raciocínio flui de forma incremental; **high** apresenta o raciocínio em um bloco final.

Note

Para a API Converse, passe o parâmetro **reasoningConfig** em **additionalModelRequestFields**.

toolConfig

toolConfig: (opcional) configuração da ferramenta seguindo o [esquema ToolConfiguration](#).

- tools: matriz de especificações de ferramentas com name, description e inputSchema
- toolChoice: (opcional) controla a seleção da ferramenta:
 - auto: o modelo decide se e quais ferramentas usar
 - any: o modelo deve usar pelo menos uma ferramenta
 - tool: o modelo deve usar a ferramenta especificada pelo nome

Estrutura completa da resposta

O seguinte trecho apresenta a estrutura de resposta completa para os modelos do 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
}
}

```

Motivos da interrupção:

- `end_turn`: fim natural da resposta
- `max_tokens`: atingiu o limite máximo de tokens
- `content_filtered`: política de conteúdo violada
- `malformed_model_output`: saída de modelo inválida
- `malformed_tool_use`: saída de uso de ferramenta inválida
- `service_unavailable`: serviço de ferramentas integradas inacessível
- `invalid_query`: consulta inválida para a ferramenta integrada
- `max_tool_invocations`: as novas tentativas de ferramentas estão esgotadas

As seguintes seções fornecem explicações detalhadas sobre cada campo de resposta:

saída

output: (Obrigatório) contém a mensagem de resposta do modelo.

- message: (obrigatório) mensagem de resposta do assistente com matriz de conteúdo e perfil.
- content: (obrigatório) matriz de blocos de conteúdo que pode incluir:
 - reasoningContent: (Opcional) retornado se o raciocínio foi ativado. Contém o texto do raciocínio, que sempre será [REDACTED] na resposta.
 - toolUse: (Opcional) retornado se uma ferramenta foi chamada. Contém o ID de uso, o nome e os argumentos de entrada da ferramenta.
 - text: (Opcional) retornado se o modelo respondeu com conteúdo de texto.
 - image: (Opcional, somente) retornado se o modelo gerou uma imagem. O formato sempre será PNG.

stopReason

stopReason: (obrigatório) indica por que o modelo parou de gerar saída:

- end_turn: chegou ao fim natural da resposta
- max_tokens: atingiu o limite máximo de tokens ou o limite máximo de saídas do modelo
- content_filtered: a saída violou a política de IA responsável da AWS
- malformed_model_output: o modelo gerou uma saída inválida
- malformed_tool_use: o modelo gerou uma saída inválida de uso da ferramenta
- service_unavailable: o serviço de ferramentas integradas não pôde ser acessado
- invalid_query: a consulta à ferramenta integrada era inválida
- max_tool_invocations: a ferramenta integrada não gerou resultados válidos após novas tentativas

uso

usage: (obrigatório) informações de uso do token:

- inputTokens: total de tokens ingeridos pelo modelo

- `outputTokens`: número de tokens gerados
- `totalTokens`: soma dos tokens de entrada e saída

métricas

`metrics`: (obrigatório) métricas de desempenho:

- `latencyMs`: tempo total de conclusão da inferência em milissegundos

Referência do SDK

Os kits de desenvolvimento de software (SDKs) da AWS estão disponíveis para muitas linguagens de programação populares. Cada SDK fornece uma API, exemplos de código e documentação que permitem que os desenvolvedores criem facilmente aplicações em seu idioma de preferência.

Documentação do SDK	Exemplos de código
AWS SDK para C++	Exemplos de códigos do AWS SDK para C++
AWS CLI	Exemplos de códigos da AWS CLI
AWS SDK para Go	Exemplos de códigos do AWS SDK para Go
AWS SDK para Java	Exemplos de códigos do AWS SDK para Java
AWS SDK para JavaScript	Exemplos de códigos do AWS SDK para JavaScript
AWS SDK para Kotlin	Exemplos de códigos do AWS SDK para Kotlin
AWS SDK para .NET	Exemplos de códigos do AWS SDK para .NET
AWS SDK para PHP	Exemplos de códigos do AWS SDK para PHP
Ferramentas da AWS para PowerShell	Exemplos de códigos das Ferramentas da AWS para PowerShell
AWS SDK para Python (Boto3)	Exemplos de códigos do AWS SDK para Python (Boto3)

Documentação do SDK	Exemplos de código
AWS SDK para Ruby	Exemplos de códigos do AWS SDK para Ruby
AWS SDK para Rust	Exemplos de códigos do AWS SDK para Rust
AWS SDK para SAP ABAP	Exemplos de códigos do AWS SDK para SAP ABAP
AWS SDK para Swift	Exemplos de códigos do AWS SDK para Swift

Personalização de modelos do Amazon Nova no SageMaker AI

Você pode personalizar os modelos do Amazon Nova, incluindo os modelos aprimorados do Amazon Nova 2.0, por meio de [fórmulas](#), e treiná-los no SageMaker. Essas fórmulas permitem técnicas como ajuste fino supervisionado (SFT) e ajuste fino por reforço (RFT), com opções de adaptação de full-rank e de baixa classificação (LoRA).

O fluxo de trabalho completo de personalização envolve etapas como treinamento de modelo, avaliação de modelo e implantação para inferência. Essa abordagem de personalização de modelos no SageMaker oferece maior flexibilidade e controle para ajustar modelos do Amazon Nova compatíveis, otimizar hiperparâmetros com precisão e implementar técnicas como LoRA, ajuste fino com eficiência de parâmetros (PEFT), SFT de full-rank, RFT e pré-treinamento contínuo (CPT).

Abordagens de personalização

O SageMaker oferece duas abordagens para personalizar os modelos do Amazon Nova:

Experiência baseada em interface de usuário: use para personalizar modelos do Amazon Nova por meio de uma interface simples e guiada. Essa abordagem fornece um fluxo de trabalho completo, incluindo treinamento, avaliação e implantação sem escrever código. A experiência baseada em interface de usuário é ideal para experimentação rápida, desenvolvimento de prova de conceito e usuários que preferem um fluxo de trabalho visual.

Experiência baseada em código: use o SageMaker Python SDK, o Nova SDK e as fórmulas de treinamento para personalizar modelos de forma programática. Essa abordagem oferece maior flexibilidade, permitindo que você configure hiperparâmetros avançados, integre-se aos pipelines de CI/CD e automatize os fluxos de trabalho de treinamento. A experiência baseada em código é recomendada para workloads de produção, requisitos complexos de personalização e equipes com práticas estabelecidas de MLOps.

Abordagem	Melhor para	Benefícios principais
Baseado em interface de usuário	Experimentação, prototipagem, iterações rápidas	Configuração simples, fluxo de trabalho guiado, sem necessidade de codificação

Abordagem	Melhor para	Benefícios principais
Baseado em código	Produção, automação, configurações avançadas	Flexibilidade total, integração de pipeline, controle de versão

Plataformas de personalização

A AWS oferece três plataformas para personalizar os modelos do Amazon Nova, cada uma projetada para diferentes casos de uso e requisitos:

Amazon Bedrock: fornece o caminho mais fácil e rápido para a personalização de modelos com configuração mínima. O Bedrock lida com todo o gerenciamento da infraestrutura automaticamente, permitindo que você se concentre em seus dados e casos de uso. Essa plataforma é ideal quando você precisa do menor tempo de retorno do investimento e prefere uma experiência totalmente gerenciada.

Tarefas de treinamento do SageMaker: oferecem um ambiente totalmente gerenciado para personalizar modelos do Amazon Nova, em que você não precisa criar nem manter nenhum cluster. O serviço gerencia automaticamente todo o provisionamento, a escalabilidade e o gerenciamento de recursos de infraestrutura, permitindo que você se concentre na configuração dos parâmetros de treinamento e no envio da tarefa. Essa plataforma oferece um equilíbrio entre facilidade de uso e flexibilidade, compatível com técnicas como ajuste fino com eficiência de parâmetros (PEFT), ajuste fino de full-rank e ajuste fino por reforço (RFT).

SageMaker HyperPod: oferece um ambiente especializado para treinamento distribuído em larga escala, exigindo que você crie e gerencie clusters do EKS com grupos de instâncias restritas (RIGs). Essa plataforma oferece máxima flexibilidade na configuração do ambiente de treinamento com instâncias de GPU especializadas e armazenamento integrado do Amazon FSx para Lustre, o que a torna particularmente adequada para cenários avançados de treinamento distribuído, desenvolvimento contínuo de modelos e workloads de personalização em nível empresarial.

Plataforma	Complexidade	Flexibilidade	Melhor para
Amazon Bedrock	Menor	Standard	Personalização mais rápida, configuração mínima

Plataforma	Complexidade	Flexibilidade	Melhor para
Tarefas de treinamento do SageMaker	Médio	Alto	Flexibilidade equilibrada e facilidade de uso
SageMaker HyperPod	Mais alto	Máximo	Grande treinamento distribuído, workloads empresariais

Note

Se você fornecer uma chave do KMS para sua tarefa de treinamento de personalização de modelos do Amazon Nova para criptografia no bucket do S3 de saída de propriedade da Amazon:

- Você deve fornecer a mesma chave do KMS ao chamar tarefas de treinamento iterativas subsequentes ou ao chamar a API `CreateCustomModel` do Amazon Bedrock usando o modelo criptografado.
- A identidade que chama a API `CreateTrainingJob` (em vez do perfil de execução) deve ter permissões para `CreateGrant`, `RetireGrant`, `Encrypt` e `GenerateDataKey`, conforme definido na política de chave do KMS.

Pré-requisitos gerais

O processo de personalização envolve vários estágios principais, como treinamento, avaliação e implantação de modelos para inferência, cada um exigindo recursos e configurações específicos. Antes de começar a personalizar seus modelos do Amazon Nova no SageMaker, verifique se você atende aos pré-requisitos gerais a seguir.

- Um Conta da AWS. Se você não tiver uma Conta da AWS, siga [estas instruções](#) para cadastrar-se em uma.
- [Instalar a AWS CLI](#) e [Definir a configuração](#).
- Acesso às [fórmulas básicas de personalização de modelo do Amazon Nova](#).
- Familiaridade com os arquivos de configuração [YAML](#).
- Familiaridade com a execução de um caderno em seu ambiente.

- Familiaridade com a criação de recursos da AWS, como buckets do [Amazon S3](#) e [perfis do IAM](#) com as permissões apropriadas.
- Familiaridade com o [treinamento de modelos com o SageMaker](#).
- Familiaridade com o [SageMaker HyperPod com orquestração do EKS](#).
- Familiaridade com a [CLI do SageMaker HyperPod](#).
- Familiaridade com [modelos de base do Amazon Nova](#).
- Familiaridade com [modelos e algoritmos disponíveis do Amazon Nova para personalização](#).
- Familiaridade com a [inferência do Amazon Bedrock](#).

Fórmulas do Amazon Nova

Você pode obter uma fórmula do Amazon Nova no repositório de [fórmulas](#). Uma fórmula do Amazon Nova é um arquivo de configuração [YAML](#) que fornece ao SageMaker detalhes sobre como executar a tarefa de personalização de modelos. Ela fornece o nome do modelo de base, define os hiperparâmetros de treinamento, configura as definições de otimização e inclui todas as opções adicionais necessárias para ajustar ou treinar o modelo com sucesso.

Você também pode acessar as fórmulas do Amazon Nova por meio do SageMaker AI Monarch, navegando até o hub de modelos, selecionando AWS e explorando os modelos do Amazon Nova para encontrar suas fórmulas correspondentes. O SageMaker AI Monarch e fornecem exemplos de caderno para cada fórmula, que incluem todas as etapas necessárias para modificar as fórmulas e executar tarefas de personalização usando tarefas de treinamento do SageMaker ou ambientes do SageMaker HyperPod.

Para acessar as páginas de fórmulas do Amazon SageMaker Studio, o perfil de execução deve ter as permissões a seguir.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "s3:GetObject"
      ]
    }
  ]
}
```

```

    ],
    "Resource": [
        "arn:aws:s3:::*model-customization-recipes*"
    ]
}
]
}

```

Para executar os cadernos de exemplo nas tarefas de treinamento do SageMaker e no SageMaker HyperPod, use uma das seguintes versões de imagem de distribuição do SageMaker: 2.7.1+, 2.8.0+, 3.2.1+ e 3.3.0+. Isso se aplica tanto ao SageMaker AI Monarch quanto ao .

Tópicos

- [Obter fórmulas do Amazon Nova](#)
- [Obtenção de fórmulas do Amazon Nova Forge](#)
- [Modelos e algoritmos disponíveis](#)
- [Amazon Nova 2.0 Lite](#)

Obter fórmulas do Amazon Nova

Para obter uma fórmula básica do Amazon Nova, clone o repositório de [fórmulas](#) executando o comando a seguir.

```
git clone https://github.com/aws/sagemaker-hyperpod-recipes.git
```

As fórmulas básicas estão disponíveis em [recipes_collection/recipes/](#).

```
cd recipes_collection/recipes/
```

As fórmulas de personalização do Amazon Nova estão nas pastas a seguir.

Tipo de fórmula	Pasta
SFT (full-rank e PEFT)	fine-tuning/nova
Avaliação	evaluation/nova

Tipo de fórmula	Pasta
CPT	training/nova

Obtenção de fórmulas do Amazon Nova Forge

Para acessar fórmulas especializadas do Amazon Nova Forge para tarefas, [configure seu acesso ao Amazon Nova Forge](#) e, em seguida, assista a [este workshop](#) para configurar a versão do Forge da CLI. Para tarefas de treinamento do SageMaker, o Console da AWS e o Nova Forge SDK acessarão automaticamente as fórmulas do Forge.

Modelos e algoritmos disponíveis

A tabela a seguir resume a disponibilidade de personalização de modelos do Amazon Nova e de algoritmos compatíveis usando o SageMaker.

Nome do modelo	ID do modelo	Ajustar	Observações
Amazon Nova Lite 2.0	amazon.nova-2-lite-v1:0:256k	Sim	• SFT: aceita texto e/ou imagem ou texto e/ou vídeo como entrada e produz texto como saída. Uma única tarefa não pode combinar texto, imagem e vídeo na mesma execução. • RFT: aceita texto e imagem como entrada para conversas de turno único e gera texto como saída. Recursos aprimorados de

Nome do modelo	ID do modelo	Ajustar	Observações
			otimização de recompensas.
			• CPT

Amazon Nova 2.0 Lite

A tabela abaixo lista informações detalhadas das fórmulas de referência do Amazon Nova 2.0 Lite.

Modelo	Categoria / subcategoria	Técnica	Nome da fórmula	URI da imagem (tarefas de treinamento)	URI da imagem (SageMaker HyperPod)	Instância de computação
Nova 2.0 Lite	Treinamento	Pré-treinamento contínuo	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	Ajuste fino com eficiência	Ajuste	nova_lite_2_0_p5_gpu_lora_sft.yaml	708977205387.dkr.ecr.us-east-1.amazo	708977205387.dkr.ecr.us-east-1.amazo	m1.p5.48xlarge, m1.p5en.48xlarge

Modelo	Categoria / subcategoria	Técnica	Nome da fórmula	URI da imagem (tarefas de treinamento)	URI da imagem (SageMaker HyperPod)	Instância de computação
	parâmetros			naws.com/nova-fine-tune-repo:SM-TJ-SFT-V2-latest	naws.com/nova-fine-tune-repo:SM-HP-SFT-V2-latest	
Nova 2.0 Lite	Ajuste fino de full-rank	Ajuste	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

Modelo	Categoria / subcategoria	Técnica	Nome da fórmula	URI da imagem (tarefas de treinamento)	URI da imagem (SageMaker HyperPod)	Instância de computação
Nova 2.0 Lite	RFT com eficiência de parâmetros	Ajuste	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

Modelo	Categoria / subcategoria	Técnica	Nome da fórmula	URI da imagem (tarefas de treinamento)	URI da imagem (SageMaker HyperPod)	Instância de computação
Nova 2.0 Lite	RFT de full-rank	Ajuste	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	ml.p5.48xlarge, ml.p5en.48xlarge

Modelo	Categoria / subcategoria	Técnica	Nome da fórmula	URI da imagem (tarefas de treinamento)	URI da imagem (SageMaker HyperPod)	Instância de computação
Nova 2.0 Lite	Traga seus próprios dados	Avaliação	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-V2-1-atest	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-HP-Eval-V2-1-atest	ml.p5.48xlarge, ml.p5en.48xlarge

Modelo	Categoria / subcategoria	Técnica	Nome da fórmula	URI da imagem (tarefas de treinamento)	URI da imagem (SageMaker HyperPod)	Instância de computação
Nova 2.0 Lite	Benchmark geral de texto	Avaliação	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-V2-1-atest	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-HP-Eval-V2-1-atest	ml.p5.48xlarge, ml.p5en.48xlarge

Modelo	Categoria / subcategoria	Técnica	Nome da fórmula	URI da imagem (tarefas de treinamento)	URI da imagem (SageMaker HyperPod)	Instância de computação
Nova 2.0 Lite	Avaliação de RFT	Avaliação	nova_lite_2_0_p5_48x1_gpu_rft_eval.yaml	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-TJ-Eval-V2-1-atest	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-HP-Eval-V2-1-atest	ml.p5.48xlarge, ml.p5en.48xlarge

Modelo	Categoria / subcategoria	Técnica	Nome da fórmula	URI da imagem (tarefas de treinamento)	URI da imagem (SageMaker HyperPod)	Instância de computação
Nova 2.0 Lite	LLM como avaliador baseado em critérios	Avaliação	nova_lite_2_0_p5_48x1_gpu_distribution- ubric_llm_judge_eval.yaml	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-TJ-Eval-V2-latest	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-HP-Eval-V2-latest	ml.p5.48xlarge, ml.p5en.48xlarge

Personalização do Amazon Nova em tarefas de treinamento do SageMaker

As tarefas de treinamento do SageMaker são um ambiente que permite treinar modelos de machine learning em grande escala. Esse ambiente provisiona e escala automaticamente os recursos de computação, carrega dados de treinamento de origens como o Amazon S3, executa o código de treinamento e armazena os artefatos de modelo resultantes.

O objetivo do treinamento é personalizar o modelo de base do Amazon Nova usando seus dados proprietários. O processo de treinamento geralmente envolve etapas para preparar seus dados, escolher uma [fórmula](#), modificar os parâmetros de configuração nos arquivos YAML e enviar uma tarefa de treinamento. Ele produzirá um ponto de verificação de modelo treinado em um bucket do Amazon S3 gerenciado pelo serviço. Você pode usar esse local de ponto de verificação para tarefas de avaliação. A personalização do Nova em tarefas de treinamento do SageMaker AI armazena

artefatos de modelo em um bucket do Amazon S3 gerenciado pelo serviço. Os artefatos no bucket gerenciado pelo serviço são criptografados com chaves do KMS gerenciadas pelo SageMaker AI. No momento, os buckets do Amazon S3 gerenciados pelo serviço não são compatíveis com criptografia de dados usando chaves do KMS gerenciadas pelo cliente.

Práticas recomendadas para personalização do Amazon Nova

Visão geral

Esta seção fornece uma visão geral das técnicas de personalização e ajuda você a escolher a melhor abordagem para suas necessidades e dados disponíveis.

Duas etapas do treinamento de LLM

O treinamento de grandes modelos de linguagem consiste em duas etapas principais: pré-treinamento e pós-treinamento. Durante o pré-treinamento, o modelo processa tokens de texto bruto e otimiza a predição do próximo token. Esse processo cria um completador de padrões que absorve a sintaxe, a semântica, os fatos e os padrões de raciocínio da web e do texto selecionado. No entanto, o modelo pré-treinado não compreende as instruções, as metas do usuário ou o comportamento adequado ao contexto. Ele continua o texto em qualquer estilo adequado à sua distribuição de treinamento. Um modelo pré-treinado é preenchido automaticamente em vez de seguir as instruções, produz formatação inconsistente e pode refletir vieses indesejáveis ou conteúdo inseguro provenientes dos dados de treinamento. O pré-treinamento desenvolve a competência geral, não a utilidade da tarefa.

O pós-treinamento transforma o completador de padrões em um assistente útil. Você executa várias rodadas de ajuste fino supervisionado (SFT) para ensinar o modelo a seguir instruções, a aderir a esquemas e políticas, a chamar ferramentas e a gerar resultados confiáveis imitando demonstrações de alta qualidade. Esse alinhamento ensina o modelo a responder aos prompts como tarefas, em vez de texto para continuar. Em seguida, você aplica o ajuste fino pro reforço (RFT) para otimizar o comportamento usando feedback mensurável (como verificadores ou um LLM como avaliador), equilibrando compensações como precisão versus brevidade, segurança versus cobertura ou raciocínio em várias etapas sob restrições. Na prática, você alterna o SFT e o RFT em ciclos para transformar o modelo pré-treinado em um sistema confiável e alinhado a políticas que executa tarefas complexas de forma consistente.

Escolher a abordagem certa de personalização

Nesta seção, abordaremos as estratégias de personalização pós-treinamento: RFT e SFT.

Ajuste fino por reforço (RFT)

O ajuste fino por reforço melhora o desempenho do modelo por meio de sinais de feedback (pontuações mensuráveis ou recompensas que indicam a qualidade da resposta) em vez de supervisão direta com respostas exatas e corretas. Ao contrário do ajuste fino supervisionado tradicional que aprende com pares de entrada e saída, o RFT usa funções de recompensa para avaliar as respostas do modelo e otimiza iterativamente o modelo para maximizar essas recompensas. Essa abordagem funciona bem para tarefas em que definir a saída correta exata é um desafio, mas você pode avaliar com segurança a qualidade da resposta. O RFT permite que os modelos aprendam comportamentos e preferências complexos por meio de testes e feedback, tornando-o ideal para aplicações que exigem uma tomada de decisão diferenciada, uma solução criativa de problemas ou uma adesão a critérios de qualidade específicos que você pode avaliar de forma programática. Por exemplo, responder a questões jurídicas complexas é um caso de uso ideal para o RFT porque você quer ensinar ao modelo como raciocinar melhor para responder a perguntas com mais precisão.

Como funciona

No ajuste fino por reforço, você parte de uma linha de base ajustada às instruções e trata cada prompt como um pequeno torneio. Para uma determinada entrada, você coleta amostras de algumas respostas candidatas do modelo, pontua cada uma com a função de recompensa e as classifica dentro desse grupo. A etapa de atualização aprimora o modelo para tornar os candidatos com a pontuação mais alta os mais prováveis na próxima vez, e os com pontuação mais baixa os menos prováveis, enquanto uma restrição de proximidade à linha de base evita o desvio de comportamento, a verbosidade ou o tom exploratório. Você repete esse ciclo em vários prompts, atualizando casos difíceis, reforçando os verificadores ou avaliando rubricas quando vê um tom exploratório e rastreando continuamente as métricas das tarefas.

Quando usar o RFT

As tarefas que mais se beneficiam do RFT compartilham várias características. Elas têm sinais de sucesso mensuráveis, mesmo quando é difícil especificar uma única saída correta. Elas admitem pontuação parcial ou qualidade escalonada para que você possa classificar as melhores e piores respostas em um prompt ou usando uma função de recompensa. Elas envolvem vários objetivos que devem ser equilibrados (como precisão com brevidade, clareza, segurança ou custo). Elas exigem a adesão a restrições explícitas que podem ser verificadas de forma programática. Elas operam em ambientes mediados por ferramentas ou baseados no ambiente, em que os resultados são observáveis (sucesso ou falha, latência, uso de recursos). Elas ocorrem em regimes de poucos

rótulos, em que a coleta de alvos de referência é dispendiosa, mas o feedback automatizado ou baseado em rubricas é abundante. O RFT funciona melhor quando você pode transformar a qualidade em um escalar ou uma classificação confiável e deseja que o modelo amplifique preferencialmente os comportamentos de maior pontuação sem precisar de metas rotuladas exaustivas.

Considere outros métodos quando:

- Você tem pares de entrada-saída rotulados, abundantes e confiáveis: use o SFT
- A principal lacuna é o conhecimento ou o jargão: use a geração aumentada via recuperação (RAG)
- O sinal de recompensa apresenta ruído ou falta de confiabilidade, sem possibilidade de correção via rubricas ou verificadores: estabilize esse ponto antes de prosseguir com o RFT

Quando não usar o RFT

Evite o RFT nestas situações:

- Você pode produzir de forma barata pares de entrada-saída rotulados confiáveis (o SFT é mais simples, barato e mais estável)
- A lacuna é conhecimento ou jargão, em vez de comportamento (use a RAG)
- Seu sinal de recompensa apresenta ruído, é esparso, fácil de burlar ou tem computação cara ou lenta (corrija o avaliador primeiro)
- O desempenho da linha de base é próximo de zero (inicialize com o SFT antes de otimizar as preferências)
- A tarefa tem esquemas determinísticos, formatação estrita ou uma única resposta correta (SFT ou validação baseada em regras funciona melhor)
- Limitações rígidas de latência ou orçamento não suportam a amostragem ou exploração extra exigida pelo RFT
- As restrições de segurança ou políticas não são especificadas de forma precisa e aplicáveis na recompensa

Se você puder apontar para “a resposta certa”, use o SFT. Se você precisar de novos conhecimentos, use a RAG. Use o RFT somente depois de ter uma linha de base sólida e uma função de recompensa robusta, rápida e difícil de explorar.

Ajuste fino supervisionado (SFT)

O ajuste fino supervisionado treina o LLM em um conjunto de dados de pares de entrada-saída rotulados por humanos para sua tarefa. Você fornece exemplos de prompts (perguntas, instruções etc.) junto com as respostas corretas ou desejadas e continua treinando o modelo com base nelas. O modelo ajusta o peso para minimizar uma perda supervisionada (normalmente entropia cruzada entre suas previsões e os tokens de saída esperados). Esse é o mesmo treinamento usado na maioria das tarefas supervisionadas de machine learning, aplicado para especializar um LLM.

O SFT muda o comportamento, não o conhecimento. Ele não ensina ao modelo novos fatos ou jargões que não foram vistos no pré-treinamento. Ele ensina ao modelo como responder, não o que saber. Se você precisar de um novo conhecimento de domínio (como terminologia interna), use a geração aumentada via recuperação (RAG) para fornecer esse contexto no momento da inferência. Posteriormente, o SFT incorpora o comportamento de seguimento de instruções desejado à estrutura do modelo.

Como funciona

O SFT otimiza o LLM minimizando a perda média de entropia cruzada nos tokens de resposta, tratando os tokens de prompts como contexto e mascarando-os da perda. O modelo internaliza seu estilo alvo, estrutura e regras de decisão, aprendendo a gerar a finalização correta para cada prompt. Por exemplo, para classificar documentos em categorias personalizadas, você ajusta o modelo com prompts (o texto do documento) e conclusões rotuladas (os rótulos das categorias). Você treina nesses pares até que o modelo gere o rótulo correto para cada prompt com alta probabilidade.

Você pode executar o SFT com apenas algumas centenas de exemplos e aumentar a escala verticalmente até algumas centenas de milhares. As amostras do SFT devem ser de alta qualidade e estar diretamente alinhadas com o comportamento desejado do modelo.

Quando usar o SFT

O SFT é melhor quando você tem uma tarefa bem definida com as saídas desejadas claras. Se você puder declarar explicitamente “Dada a entrada X, a saída correta/desejada é Y” e reunir exemplos desses mapeamentos, o ajuste fino supervisionado será uma ótima opção. O SFT se destaca nestes cenários:

- Tarefas de classificação estruturadas ou complexas: classificar documentos ou contratos internos em várias categorias personalizadas. Com o SFT, o modelo aprende essas categorias específicas muito melhor do que apenas gerando prompts.

- Tarefas de questionamento e resposta ou transformação com respostas conhecidas: ajustar um modelo para responder a perguntas da base de conhecimentos de uma empresa ou converter dados entre formatos, em que cada entrada tem uma resposta correta.
- Formatação e consistência de estilo: treine o modelo para que sempre responda em um determinado formato ou tom, ajustando exemplos do formato ou tom correto. Por exemplo, o treinamento em pares de prompt-resposta que demonstram uma voz de marca específica ensina o modelo a gerar saídas com esse estilo. O comportamento de seguir as instruções geralmente é ensinado logo no início via SFT em exemplos selecionados de bom comportamento do assistente.

O SFT é a maneira mais direta de ensinar a um LLM uma nova habilidade ou comportamento quando você pode especificar qual é o comportamento correto. Ele aproveita a compreensão da linguagem existente do modelo e a concentra em sua tarefa. Use o SFT quando quiser que o modelo faça algo específico e você tiver ou puder criar um conjunto de dados de exemplos.

Use o SFT quando puder montar pares de prompts e respostas de alta qualidade que reflitam com precisão o comportamento desejado. Ele se adapta a tarefas com metas claras ou formatos determinísticos, como esquemas, chamadas de funções ou ferramentas e respostas estruturadas, em que a imitação é um sinal de treinamento apropriado. O objetivo é moldar o comportamento: ensinar o modelo a tratar prompts como tarefas, seguir instruções, adotar políticas de tom e recusa e produzir uma formatação consistente. Planeje pelo menos centenas de demonstrações, com a qualidade, a consistência e a deduplicação de dados sendo mais importante do que o volume bruto. Para uma atualização direta e econômica, use métodos eficientes em termos de parâmetros, como o Low-Rank Adaptation, para treinar adaptadores pequenos e, ao mesmo tempo, deixar a maior parte da estrutura intocada.

Quando não usar o SFT

Não use o SFT quando a lacuna for conhecimento e não comportamento. Ele não ensina ao modelo novos fatos, jargões ou eventos recentes. Nesses casos, use a geração aumentada via recuperação para trazer conhecimento externo para inferência. Evite o SFT quando você pode avaliar a qualidade, mas não consegue rotular uma única resposta certa. Use o ajuste fino por reforço com recompensas verificáveis ou um LLM como avaliador para otimizar essas recompensas diretamente. Se suas necessidades ou conteúdo mudarem com frequência, priorize a recuperação e o uso de ferramentas em vez de treinar novamente o modelo.

Tópicos

- [Nova Forge SDK](#)

- [Treinamento para modelos do Amazon Nova](#)
- [Monitoramento do progresso em todas as iterações](#)
- [Avaliar o modelo treinado do SageMaker AI](#)
- [Treinamento iterativo](#)

Nova Forge SDK

O Nova Forge SDK é um SDK de Python abrangente para personalizar modelos do Amazon Nova. O SDK oferece uma interface unificada para treinamento, avaliação, monitoramento, implantação e inferência de modelos do Amazon Nova em diferentes plataformas, incluindo o SageMaker AI e Amazon Bedrock. Se você está adaptando modelos para tarefas específicas do domínio ou otimizando a performance para seu caso de uso, esse SDK fornece tudo o que você precisa em uma interface unificada.

Benefícios

- Um SDK para todo o ciclo de vida da personalização do modelo, desde a preparação dos dados até a implantação e o monitoramento.
- Suporte para vários métodos de treinamento, incluindo pré-treinamento contínuo (CPT), ajuste fino supervisionado (SFT), otimização de preferência direta (DPO) e ajuste fino por reforço (RFT), tanto de turno único quanto de vários turnos, com abordagens LoRA e full-rank.
- Suporte integrado para tarefas de treinamento do SageMaker, SageMaker HyperPod e Amazon Bedrock com gerenciamento automático de recursos.
- Não é mais necessário encontrar o URI de contêiner ou as fórmulas corretas para suas técnicas de treinamento.
- Traga suas próprias fórmulas de treinamento ou use os padrões inteligentes do SDK com substituições de parâmetros.
- O SDK valida sua configuração em relação às combinações de modelos e instâncias compatíveis e fornece suporte à validação, evitando erros antes do início do treinamento.
- O monitoramento integrado do Amazon CloudWatch permite que você acompanhe o progresso do treinamento em tempo real.
- MLflow integrado para acompanhar experimentos de treinamento com os servidores de rastreamento MLflow do SageMaker AI.

Requisitos

O SDK requer pelo menos o Python 3.12.

Instalação

Para instalar esse SDK, siga o comando abaixo.

```
pip install amzn-nova-forge
```

Modelos e técnicas compatíveis

O SDK é compatível com os seguintes modelos e técnicas dentro da família do Amazon Nova:

Método	Modelos compatíveis
Pré-treinamento contínuo	Todos os modelos Nova (somente SMHP)
Ajuste fino supervisionado LoRA	Todos os modelos Nova
Ajuste fino supervisionado full-rank	Todos os modelos Nova (somente SMHP e SMTJ)
Otimização direta de preferências LoRA	Modelos Nova 1.0 (somente SMHP e SMTJ)
Otimização direta de preferências full-rank	Modelos Nova 1.0 (somente SMHP e SMTJ)
Ajuste fino por reforço LoRA	Nova Lite 2.0
Ajuste fino por reforço full-rank	Nova Lite 2.0 (somente SMHP e SMTJ)
Ajuste fino por reforço de várias turnos LoRA	Nova Lite 2.0 (somente SMHP)
Ajuste fino por reforço de vários turnos full-rank	Nova Lite 2.0 (somente SMHP)

Conceitos básicos

Tópicos

- [1. Preparar seus dados](#)

- [2. Configurar sua infraestrutura](#)
- [3. Treinamento](#)
- [4. Monitor](#)
- [5. Avaliar](#)
- [6. Implantar](#)

1. Preparar seus dados

Carregue seu conjunto de dados de arquivos locais ou do S3 e deixe que o SDK faça a transformação para o formato correto para o método de treinamento escolhido. Ou forneça dados formatados e comece imediatamente.

```
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. Configurar sua infraestrutura

Escolha seus recursos de computação. O SDK valida as configurações e garante a configuração ideal.

```
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. Treinamento

Comece a treinar com apenas algumas linhas de código.

```
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. Monitor

Acompanhe seu progresso no treinamento diretamente no 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. Avaliar

Avalie a performance do modelo com uma variedade de [avaliações comparativas integradas](#), ou crie suas próprias avaliações.

```
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. Implantar

Implante seu modelo personalizado para produção com suporte integrado para o Amazon Bedrock ou 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",
    }
)
```

Principais recursos

Criação de fórmulas em tempo real

O SDK elimina a necessidade de pesquisar as fórmulas apropriadas ou o URI de contêiner para técnicas específicas.

Processamento inteligente de dados

O SDK transforma automaticamente seus dados no formato correto para treinamento. Se você estiver trabalhando com arquivos JSON, JSONL ou CSV, o carregador de dados processará a conversão sem problemas. O carregador de dados é compatível com texto e dados multimodais (imagens e vídeos).

Suporte à infraestrutura de empresas

O SDK funciona tanto com tarefas de treinamento do SageMaker quanto com o SageMaker HyperPod, gerenciando automaticamente:

- Validação do tipo de instância
- Validação da fórmula
- Validação do conjunto de dados
- Monitoramento e orquestração de tarefas

O SDK também é compatível com a personalização de tarefas de treinamento do SageMaker sem servidor e do Bedrock.

Avaliação abrangente

Avalie seus modelos personalizados em relação às [avaliações comparativas padrão](#), incluindo:

- MMLU (Massive Multitask Language Understanding)
- BBH (Advanced Reasoning Tasks)
- GPQA (Graduate-Level Google-Proof Q&A)

Use os padrões de avaliação comparativa ou modifique-os para atender às suas necessidades:

- BYOM (traga sua própria métrica)
- BYOD (traga seu próprio conjunto de dados)

Implantação na produção

Implante seus modelos no Amazon Bedrock ou no SageMaker AI com opções para:

- Throughput provisionado do Bedrock: capacidade dedicada para performance consistente
- Bedrock sob demanda (aplicável apenas à personalização baseada em LoRA): preço conforme o uso
- Inferência em tempo real do SageMaker AI: capacidade dedicada para performance consistente

Inferência em lote

Execute tarefas de inferência em grande escala com eficiência:

- Processe milhares de solicitações em paralelo
- Agregação automática de resultados
- Processamento em lote de baixo custo

Nova Forge

Para assinantes do Nova Forge, o SDK é compatível com fórmulas de combinação de dados.

Saiba mais

Tudo pronto para começar a personalizar os modelos Nova com o Nova Forge SDK? Confira nosso repositório do GitHub para obter guias detalhados, referências de APIs e exemplos adicionais:

<https://github.com/aws/nova-forge-sdk>

Treinamento para modelos do Amazon Nova

O treinamento de modelos do Amazon Nova nas tarefas de treinamento do SageMaker é compatível com o ajuste fino supervisionado (SFT) e o ajuste fino por reforço (RFT). Cada técnica atende a diferentes necessidades de personalização e pode ser aplicada a diferentes versões de modelos do Amazon Nova.

Tópicos

- [Ajustar o Nova 2.0](#)
- [Ajuste fino por reforço \(RFT\) com modelos do Amazon Nova](#)

Ajustar o Nova 2.0

Pré-requisitos

Antes de iniciar uma tarefa de treinamento, observe o seguinte:

- Os buckets do Amazon S3 para armazenar seus dados de entrada e as saídas das tarefas de treinamento. Você pode usar um bucket para ambos ou buckets separados para cada tipo de dados. Seus buckets devem estar na mesma Região da AWS onde você cria todos os outros recursos para treinamento. Para ter mais informações, consulte [Criar um bucket de uso geral](#).
- Um perfil do IAM com permissões para executar uma tarefa de treinamento. Você deve anexar uma política do IAM com `AmazonSageMakerFullAccess`. Para obter mais informações, consulte [Como usar os perfis de execução do SageMaker AI](#).
- Fórmulas básicas do Amazon Nova, consulte [???](#).

O que é SFT?

O ajuste fino supervisionado (SFT) treina um modelo de linguagem usando pares de entrada-saída rotulados. O modelo aprende com exemplos de demonstração que consistem em prompts e respostas, refinando suas capacidades para se alinhar a tarefas específicas, instruções ou comportamentos desejados.

Preparação de dados

Visão geral

Os dados do Nova 2.0 SFT usam o mesmo formato de API Converse do Nova 1.0, com a adição de campos de conteúdo de raciocínio opcionais. Para obter as especificações completas do formato, consulte:

- Conteúdo de raciocínio: [ReasoningContentBlock](#)
- Esquema da API Converse: [API Converse](#)
- Restrições do conjunto de dados: [Restrições do conjunto de dados](#)

Recursos compatíveis

- Tipos de entrada: texto, imagem ou vídeo em blocos de conteúdo do usuário
- Conteúdo do assistente: respostas somente em texto e conteúdo de raciocínio

- Composição do conjunto de dados: deve ser homogênea. Escolha uma destas opções:
 - Turnos somente com texto
 - Turnos de texto e imagem
 - Turnos de texto e vídeo (compatível com compreensão do documento)

Important

Você não pode misturar imagens e vídeos no mesmo conjunto de dados ou em turnos diferentes.

Limitações atuais

- Conteúdo de raciocínio multimodal: embora o formato Converse ofereça suporte a conteúdo de raciocínio baseado em imagem, o Nova 2.0 SFT é compatível somente com conteúdo de raciocínio baseado em texto no campo reasoningText.
- Conjuntos de validação: você não pode fornecer um conjunto de dados de validação para SFT com o Nova 2.0. Se você fornecer um conjunto de dados de validação, ele será ignorado durante o treinamento. Essa limitação se aplica tanto aos envios de trabalhos programáticos quanto baseados na interface do usuário.

Formatos de mídia compatíveis

- Imagens: PNG, JPEG, GIF
- Vídeos: MOV, MKV, MP4

Exemplos de formato de dados

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"
    }
  ]
}
]
}

```

Chamada de ferramentas

O Nova 2.0 SFT é compatível com modelos de treinamento em padrões de chamada de ferramentas, permitindo que seu modelo aprenda quando e como invocar ferramentas ou funções externas.

Formato de dados para chamada de ferramentas

Os dados de treinamento de chamada de ferramentas incluem uma seção `toolConfig` que define as ferramentas disponíveis, além de turnos de conversa que demonstram os padrões de uso da ferramenta.

Exemplo de entrada

```

{
  "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"
    ]
}
}
}
},
],
},
{
    "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?"
    }
  ]
}
]
}
}

```

Requisitos de chamada de ferramentas

Ao criar dados de treinamento de chamada de ferramentas, siga estes requisitos:

Requisito	Descrição
Posicionamento do ToolUse	O ToolUse deve aparecer somente nos turnos do assistente

Requisito	Descrição
Posicionamento do ToolResult	O ToolResult deve aparecer somente nos turnos do usuário
Formato do ToolResult	O ToolResult deve ser somente texto ou JSON; outras modalidades não são compatíveis com os modelos Nova
Formato do inputSchema	O inputSchema dentro no toolSpec deve ser um objeto de esquema JSON válido
Correspondência do toolUseId	Cada ToolResult deve fazer referência a um toolUseId válido de um assistente ToolUse anterior, com cada toolUseId usado exatamente uma vez por conversa

Observações importantes

- Garanta que suas definições de ferramentas sejam consistentes em todas as amostras de treinamento
- O modelo aprende padrões de invocação de ferramentas das demonstrações que você fornece
- Inclua diversos exemplos de quando usar cada ferramenta e de quando não usá-las

Compreensão do documento

O Nova 2.0 SFT é compatível com o treinamento em tarefas baseadas em documentos, permitindo que seu modelo aprenda a analisar e responder a perguntas sobre documentos PDF.

Formato de dados para compreensão do documento

Os dados de treinamento de compreensão de documentos incluem referências de documentos nos blocos de conteúdo do usuário, com o modelo aprendendo a extrair e raciocinar sobre o conteúdo do documento.

Exemplo de entrada

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

```

Limitações de compreensão de documentos

Limitação	Detalhes
Formato compatível	Somente arquivos PDF
Tamanho máximo do documento	10 MB
Combinação de modalidades	Um exemplo pode ter documentos e texto, mas não pode ter documentos combinados com outras modalidades (imagens, vídeos)

Práticas recomendadas da compreensão de documentos

- Certifique-se de que os documentos estejam claramente formatados e que o texto possa ser extraído
- Forneça diversos exemplos que abrangem diferentes tipos de documentos e formatos de perguntas
- Inclua conteúdo de raciocínio para ajudar o modelo a aprender padrões de análise de documentos

Compreensão de vídeos

O Nova 2.0 SFT é compatível com o treinamento em tarefas baseadas em vídeo, permitindo que seu modelo aprenda a analisar e responder a perguntas sobre conteúdo de vídeo.

Formato de dados para a compreensão de vídeos

Os dados de treinamento de compreensão de vídeos incluem referências de vídeo nos blocos de conteúdo do usuário, com o modelo aprendendo a extrair informações e raciocinar sobre o conteúdo do vídeo.

Exemplo de entrada

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

```

Limitações de compreensão de vídeo

Limitação	Detalhes
Tamanho máximo do vídeo	50 MB
Duração máxima do vídeo	15 minutos
Vídeos por exemplo	É permitido somente um vídeo por exemplo. Inexistência de suporte para vários vídeos no mesmo exemplo
Combinação de modalidades	Um exemplo pode ter vídeo e texto, mas não pode ter vídeo combinado com outras modalidades (imagens, documentos)

Formatos de vídeo compatíveis

- MOV
- MKV
- MP4

Práticas recomendadas de compreensão de vídeos

- Mantenha os vídeos concisos e focados no conteúdo relevante para sua tarefa
- Certifique-se de que a qualidade do vídeo seja suficiente para que o modelo extraia informações significativas
- Forneça perguntas claras que façam referência a aspectos específicos do conteúdo do vídeo
- Inclua diversos exemplos que abrangem diferentes tipos de vídeo e formatos de perguntas

Modos de raciocínio vs não raciocínio

Compreensão do conteúdo de raciocínio

O conteúdo de raciocínio (também chamado de encadeamento de pensamentos) captura as etapas intermediárias do pensamento do modelo antes de gerar uma resposta final. Na vez do assistant, use o campo `reasoningContent` para incluir esses rastros de raciocínio.

Como a perda é calculada

- Com conteúdo de raciocínio: a perda de treinamento inclui tokens de raciocínio e tokens de saída final
- Conteúdo sem raciocínio: a perda de treinamento é calculada apenas com base nos tokens de saída final

Você pode incluir `reasoningContent` em vários turnos do assistente em conversas de vários turnos.

Diretrizes de formatação

- Use texto simples para o conteúdo de raciocínio
- Evite tags de marcação como `<thinking>` e `</thinking>`, a menos que sejam especificamente exigidas por sua tarefa
- Garanta que o conteúdo do raciocínio seja claro e relevante para o processo de solução de problemas

Quando habilitar o modo de raciocínio

Defina `reasoning_enabled: true` em sua configuração de treinamento quando:

- Seus dados de treinamento tiverem tokens de raciocínio
- Você quiser que o modelo gere tokens de pensamento antes de produzir as saídas finais
- Você precisar melhorar o desempenho em tarefas complexas de raciocínio

É permitido treinar o Nova em um conjunto de dados sem raciocínio com `reasoning_enabled = true`. No entanto, isso pode fazer com que o modelo perca suas capacidades de raciocínio, pois o Nova aprende principalmente a gerar as respostas presentes nos dados sem aplicar o raciocínio. Se você deseja treinar o Nova em um conjunto de dados sem raciocínio, mas ainda espera tê-lo durante a inferência, você pode desabilitar o raciocínio durante o treinamento (`reasoning_enabled = false`), mas habilitá-lo para inferência. Embora essa abordagem permita que o raciocínio seja usado no momento da inferência, ela não garante um melhor desempenho em comparação com a inferência sem raciocínio. No geral, habilite o raciocínio para o treinamento e a inferência ao usar conjuntos de dados de raciocínio, e desabilite-o para ambos ao usar conjuntos de dados sem raciocínio.

Defina `reasoning_enabled: false` quando:

- Seus dados de treinamento não tiverem tokens de raciocínio
- Você estiver treinando em tarefas simples que não se beneficiam de etapas de raciocínio explícito
- Você quiser otimizar a velocidade e reduzir o uso de tokens

Geração de dados de raciocínio

Se seu conjunto de dados não tiver rastros de raciocínio, você poderá criá-los usando um modelo capaz de raciocinar, como o Nova Premier. Forneça seus pares de entrada-saída ao modelo e capture seu processo de raciocínio para criar um conjunto de dados com raciocínio aumentado.

Uso de tokens de raciocínio para treinamento

Ao treinar com o modo de raciocínio habilitado, o modelo aprende a separar o raciocínio interno da resposta final. O processo de treinamento:

- Organiza os dados como triplos: entrada, raciocínio e resposta
- Otimiza usando a perda de previsão padrão do próximo token tanto dos tokens de raciocínio quanto dos tokens de resposta
- Incentiva o modelo a raciocinar internamente antes de gerar respostas

Conteúdo de raciocínio eficaz

O conteúdo de raciocínio de alta qualidade deve incluir:

- Pensamentos e análises intermediários
- Deduções lógicas e etapas de inferência
- Abordagens de solução de problemas passo a passo
- Conexões explícitas entre as etapas e conclusões

Isso ajuda o modelo a desenvolver a capacidade de “pensar antes de responder”.

Diretrizes de preparação de conjuntos de dados

Tamanho e qualidade

- Tamanho recomendado: 2 mil a 10 mil exemplos

- Mínimo de exemplos: 200
- Prioridade: qualidade acima da quantidade. Garanta exemplos precisos e com anotação de qualidade
- Alinhamento de aplicações: o conjunto de dados deve refletir de perto seus casos de uso de produção

Diversidade

Inclua diversos exemplos que:

- Abranjam toda a gama de entradas esperadas
- Representem diferentes níveis de dificuldade
- Incluam variações e casos de borda
- Evitem o sobreajuste a padrões limitados

Formatação de saída

Especifique claramente o formato de saída desejado nas respostas do assistente:

- estruturas JSON
- Tabelas
- Formato CSV
- Formatos personalizados específicos para sua aplicação

Conversas em vários turnos

Para conjuntos de dados de várias turnos, lembre-se:

- A perda é calculada somente nos turnos do assistente, não nos turnos do usuário
- Cada resposta do assistente deve ser formatada corretamente
- Mantenha a consistência nos turnos das conversas

Lista de verificação de qualidade

- Tamanho suficiente do conjunto de dados (2 mil a 10 mil exemplos)
- Diversos exemplos que abrangem todos os casos de uso

- Formatação de saída clara e consistente
- Rótulos e anotações precisos
- Representativo dos cenários de produção
- Livre de contradições ou ambiguidades

Carregar seus dados

Os conjuntos de dados devem ser enviados para um bucket que possa ser acessado pelas tarefas de treinamento do SageMaker. Para obter mais informações sobre como configurar as permissões corretas, consulte [Pré-requisitos](#).

Início de uma tarefa de treinamento

Seleção de hiperparâmetros e atualização da fórmula

A configuração do Nova 2.0 é basicamente a mesma do Nova 1.0. Depois que os dados de entrada forem enviados para o S3, use a fórmula das [Fórmulas do SageMaker HyperPod](#) na pasta Ajuste fino. Para o Nova 2.0, confira a seguir alguns dos principais hiperparâmetros que você pode atualizar com base no caso de uso. O que se segue é um exemplo da fórmula de SFT PEFT do Nova 2.0. Para o URI da imagem do contêiner, use `708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-TJ-SFT-V2-latest` para executar um trabalho de ajuste fino de SFT.

Use a v2.254.1 do SageMaker AI PySDK para obter compatibilidade total com o treinamento do Nova. A atualização do SDK para a v3.0 resultará em alterações disruptivas. A compatibilidade com a v3 do SageMaker AI PySDK estará disponível em breve.

Exemplo de entrada

```
!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

```

A fórmula também contém basicamente os mesmos hiperparâmetros do Nova 1.0. Os principais hiperparâmetros são:

- **max_steps**: número de etapas para as quais você deseja executar o trabalho. Geralmente, para uma época (uma execução em todo o conjunto de dados), o número de etapas = número de

amostras de dados/tamanho global do lote. Quanto maior o número de etapas e menor o tamanho do lote global, mais tempo o trabalho levará para ser executado.

- `reasoning_enabled`: controla o modo de raciocínio para seu conjunto de dados. Opções:
 - `true`: habilita o modo de raciocínio (equivalente ao raciocínio elevado)
 - `false`: desabilita o modo de raciocínio

Observação: para o SFT, não há controle granular sobre os níveis de esforço de raciocínio. A configuração `reasoning_enabled: true` habilita a capacidade total de raciocínio.

- `peft.peft_scheme`: definir como "lora" habilita o ajuste fino baseado em PEFT. Defini-lo como nulo (sem aspas) habilita o ajuste fino de full-rank.

Iniciar a tarefa de treinamento

```
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

A aprovação de um conjunto de dados de validação não é compatível com o ajuste fino supervisionado do Nova 2.0.

Para começar a tarefa:

- Atualize a fórmula com seus caminhos e hiperparâmetros do conjunto de dados
- Execute as células especificadas no caderno para enviar a tarefa de treinamento

O caderno gerencia o envio de tarefas e fornece o rastreamento de status.

Ajuste fino por reforço (RFT) com modelos do Amazon Nova

Visão geral

O que é o RFT?

O ajuste fino por reforço (RFT) melhora o desempenho do modelo treinando com sinais de feedback (pontuações mensuráveis ou recompensas que indicam o desempenho do modelo) em vez de com respostas corretas exatas. Ao contrário do ajuste fino supervisionado que aprende com pares de entrada e saída, o RFT usa funções de recompensa para avaliar as respostas do modelo e otimiza de forma iterativa o modelo para maximizar essas recompensas. Essa abordagem se destaca quando a definição exata da saída correta é difícil, mas a avaliação da qualidade da resposta é confiável.

Quando usar o RFT

Use o RFT quando você puder definir critérios de sucesso claros e mensuráveis, mas tiver dificuldade em fornecer resultados exatos e corretos para o treinamento. É ideal para:

- Tarefas em que a qualidade é subjetiva ou multifacetada (escrita criativa, otimização de código, raciocínio complexo)
- Cenários com várias soluções válidas em que algumas são claramente melhores do que outras
- Aplicações que exigem aprimoramento iterativo, personalização ou adesão a regras de negócios complexas
- Casos em que coletar exemplos rotulados de alta qualidade é caro ou impraticável

Melhores casos de uso

O RFT se destaca em domínios em que a qualidade da saída pode ser avaliada objetivamente, mas as respostas ideais são difíceis de definir de antemão:

- Resolução de problemas matemáticos e geração de código
- Raciocínio científico e análise de dados estruturados
- Tarefas que exigem raciocínio passo a passo ou solução de problemas em vários turnos
- Aplicações que equilibram vários objetivos (precisão, eficiência, estilo)
- Cenários em que o sucesso pode ser verificado de forma programática por meio de resultados de execução ou métricas de desempenho

Modelos compatíveis

Nova Lite 2.0

Visão geral do formato de dados

Os dados de treinamento do RFT devem seguir o [formato](#) de ajuste fino por reforço da OpenAI. Cada exemplo de treinamento é um objeto JSON que contém:

- Uma matriz de mensagens com turnos de conversação usando os perfis `system` e `user`
- Um campo `reference_answer` contendo o resultado esperado ou os critérios de avaliação para o cálculo da recompensa

Limitações atuais

- Somente texto

Exemplos de formato de dados

Cada exemplo deve estar em uma única linha no arquivo JSONL, com um objeto JSON por linha.

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
}
```

O campo `reference_answer` contém o resultado esperado ou os critérios de avaliação que sua função de recompensa usa para pontuar a resposta do modelo. Ele não se limita a resultados estruturados. Ele pode conter qualquer formato que ajude sua função de recompensa a avaliar a qualidade.

Recomendações de tamanho do conjunto de dados

Ponto de partida

- Mínimo de 100 exemplos de treinamento
- Mínimo de 100 exemplos de avaliação

Abordagem que prioriza a avaliação

Antes de investir em treinamento de RFT em grande escala, avalie o desempenho básico do seu modelo:

- Alto desempenho (>95% de recompensa): o RFT pode ser desnecessário, pois seu modelo já tem um bom desempenho
- Desempenho muito baixo (0% de recompensa): mude primeiro para o SFT para estabelecer os recursos básicos
- Desempenho moderado: o RFT provavelmente é apropriado

Começar com um pequeno conjunto de dados permite que você:

- Valide que sua função de recompensa está livre de bugs
- Confirme que o RFT é a abordagem certa para o seu caso de uso
- Identifique e corrija problemas com antecedência
- Teste o fluxo de trabalho antes de aumentar a escala verticalmente

Depois de validado, você pode expandir para conjuntos de dados maiores para melhorar ainda mais o desempenho.

Características dos dados de treinamento efetivos

Clareza e consistência

Bons exemplos de RFT exigem dados de entrada claros e inequívocos que permitam o cálculo preciso da recompensa em diferentes saídas do modelo. Evite ruídos em seus dados, incluindo:

- Formatação inconsistente
- Rótulos ou instruções contraditórios
- Prompts ambíguos
- Respostas de referência conflitantes

Qualquer ambiguidade induzirá o processo de treinamento ao erro, fazendo com que o modelo aprenda comportamentos indesejados.

Diversidade

Seu conjunto de dados deve capturar toda a diversidade de casos de uso de produção para garantir um desempenho robusto no mundo real. Inclusão:

- Diferentes formatos de entrada e casos de borda
- Mapear padrões reais de uso em produção de logs e analytics de usuários
- Amostra de todos os tipos de usuários, regiões geográficas e variações sazonais
- Incluir níveis de dificuldade de problemas simples a complexos

Considerações sobre a função de recompensa

Projete sua função de recompensa para um treinamento eficiente:

- Execute em segundos (não em minutos)
- Paralelize de forma eficaz com o Lambda
- Retorne pontuações consistentes e confiáveis
- Lide com diferentes tipos de saídas de modelo de forma resiliente

As funções de recompensa rápidas e escaláveis permitem uma iteração rápida e uma experimentação econômica.

Propriedades adicionais

O formato de dados de RFT é compatível com campos personalizados além dos requisitos principais do esquema (`messages` e `reference_answer`). Essa flexibilidade permite que você adicione quaisquer dados adicionais de que sua função de recompensa precise para uma avaliação adequada.

Note

Você não precisa configurar isso em sua fórmula. O formato de dados é inerentemente compatível com campos adicionais. Basta incluí-los em seus dados de treinamento JSON e eles serão passados para sua função de recompensa no campo `metadata`.

Propriedades comuns adicionais

Campos de metadados de exemplo:

- `task_id`: identificador único de rastreamento
- `difficulty_level`: indicador de complexidade do problema
- `domain`: área ou categoria do assunto
- `expected_reasoning_steps`: número de etapas na solução

Exemplo com propriedades adicionais

```
{
  "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
}

```

Esses campos adicionais são passados para sua função de recompensa durante a avaliação, permitindo uma lógica de pontuação sofisticada adaptada ao seu caso de uso específico.

Configuração do treinamento

Exemplo de fórmula

```

# 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)
```

Treinamento de RFT usando o LLM como avaliador

Visão geral

Os grandes modelos de linguagem (LLMs) estão sendo cada vez mais usados como avaliadores em fluxos de trabalho de ajuste fino por reforço (RFT), fornecendo sinais de recompensa automatizados que orientam a otimização do modelo. Nessa abordagem, um LLM avalia os resultados do modelo em relação a critérios específicos, seja avaliando a exatidão, a qualidade, a aderência ao estilo ou a equivalência semântica, e atribui recompensas que impulsionam o processo de aprendizado por reforço.

Isso é particularmente valioso para tarefas em que as funções de recompensa tradicionais são difíceis de definir de forma programática, como determinar se representações diferentes (como “1/3”, “0,333” e “um terço”) são semanticamente equivalentes, ou avaliar qualidades subjetivas, como coerência e relevância. Ao usar avaliadores baseados em LLM como funções de recompensa, você pode escalar o RFT para domínios complexos sem exigir anotações humanas extensivas, permitindo uma iteração rápida e a melhoria contínua de seus modelos em diversos casos de uso, além dos problemas tradicionais de alinhamento.

Seleção do modo de raciocínio

Modos disponíveis

- none: sem raciocínio (omite o campo reasoning_effort)
- low: sobrecarga mínima de raciocínio
- high: capacidade máxima de raciocínio (padrão quando reasoning_effort é especificado)

Note

Não há a opção medium para o RFT. Se o campo reasoning_effort estiver ausente da sua configuração, o raciocínio será desabilitado. Quando o raciocínio está habilitado, você deve definir max_new_tokens como 32.768 para acomodar saídas de raciocínio estendidas.

Quando usar cada modo

Use o raciocínio high para:

- Tarefas analíticas complexas
- Resolução de problemas matemáticos
- Dedução lógica de várias etapas
- Tarefas em que o pensamento passo a passo agrega valor

Use raciocínio none (omite reasoning_effort) ou low para:

- Consultas factuais simples
- Classificações diretas
- Velocidade e otimização de custos
- Respostas diretas a perguntas

Compensações de custo e desempenho

Os modos de raciocínio mais altos aumentam:

- O tempo e o custo do treinamento
- A latência e o custo da inferência
- A capacidade de modelar para tarefas complexas de raciocínio

Validação do seu LLM como avaliador

Antes de implantar um LLM como avaliador na produção, valide se as avaliações do modelo do avaliador estão alinhadas com a avaliação humana. Isso envolve:

- Avaliar as taxas de concordância entre o LLM como avaliador e os avaliadores humanos em amostras representativas de sua tarefa
- Garantir que a concordância do LLM com humanos atinja ou supere as taxas de concordância entre humanos
- Identificar possíveis vieses no modelo do avaliador
- Criar confiança de que o sinal de recompensa guia seu modelo na direção pretendida

Essa etapa de validação ajuda a garantir que o processo de avaliação automatizado produza modelos que atendam aos seus critérios de qualidade de produção.

Configuração do Lambda para o LLM como avaliador

Usar um LLM como avaliador é uma extensão do uso das funções do Lambda para aprendizado por reforço com recompensas verificáveis (RLVR). Dentro da função do Lambda, você faz uma chamada para um dos modelos hospedados no Amazon Bedrock.

Requisitos de configuração importantes:

Configuração	Requisito	Detalhes
Throughput do Amazon Bedrock	Cota suficiente	Certifique-se de que sua cota de throughput para o modelo do Amazon Bedrock usado seja suficiente para sua workload de treinamento
tempo limite do Lambda	Tempo limite estendido	Configure o tempo limite da função do Lambda em até o máximo de 15 minutos. A configuração padrão é de 3 segundos, o que é insuficiente para as respostas dos modelos do Amazon Bedrock
Simultaneidade do Lambda	Aumento da simultaneidade	O Lambda é invocado paralelamente durante o treinamento. Aumente a simultaneidade para maximizar o throughput disponível
Configuração de fórmula	Correspondência das configurações do Lambda	O limite de simultaneidade deve ser configurado em sua fórmula

Criação e execução de tarefas

Início de uma tarefa de treinamento

Use o modelo do caderno de tarefas de treinamento do SageMaker: <https://docs.aws.amazon.com/sagemaker/latest/dg/nova-fine-tuning-training-job.html#nova-model-training-jobs-notebook>

Requisitos de instância

O contêiner é compatível com o treinamento de full-rank e LoRA:

- Treinamento LoRA: 2/4/6/8 × instâncias p5.48xlarge ou p5en.48xlarge
- Treinamento de full-rank: 2/4/6/8 × instâncias p5.48xlarge (obrigatório)

Monitoramento do treinamento

Os logs de treinamento incluem métricas abrangentes em cada etapa. Principais categorias métricas:

Métricas de recompensa

- `critic/rewards/mean`, `critic/rewards/max`, `critic/rewards/min`: distribuição de recompensas
- `val-score/rewards/mean@1`: recompensas de validação

Comportamento do modelo

- `actor/entropy`: variação da política (maior = mais exploratória)

Integridade do treinamento

- `actor/pg_loss`: perda de gradiente de política
- `actor/pg_clipfrac`: frequência de atualizações cortadas
- `actor/grad_norm`: magnitude do gradiente

Características das respostas

- `prompt_length/mean`, `prompt_length/max`, `prompt_length/min`: estatísticas dos tokens de entrada
- `response_length/mean`, `response_length/max`, `response_length/min`: estatísticas dos tokens de saída
- `response/aborted_ratio`: taxa de geração incompleta (0 = tudo concluído)

desempenho

- `perf/throughput`: throughput do treinamento

- `perf/time_per_step`: tempo por etapa de treinamento
- `timing_per_token_ms/*`: tempos de processamento por token

Uso de recursos

- `perf/max_memory_allocated_gb`, `perf/max_memory_reserved_gb`: memória da GPU
- `perf/cpu_memory_used_gb`: memória da CPU

Uso de modelos ajustados

Após a conclusão do treinamento, o ponto de verificação final do modelo é salvo no local de saída especificado. O caminho do ponto de verificação está disponível em:

- Logs de treinamento
- Arquivo `manifest.json` no local de saída do Amazon S3 (definido por `output_s3_uri` em seu caderno)

Limitações e práticas recomendadas

Limitações

- Tempo limite do Lambda: as funções de recompensa devem ser concluídas em até 15 minutos (evita processos descontrolados e gerencia custos)
- Somente um único turno: conversas em vários turnos não são compatíveis
- Requisitos de dados: precisa de diversidade suficiente; tem dificuldades com recompensas esparsas (<5% de exemplos positivos)
- Custo computacional: mais caro do que o ajuste fino supervisionado
- Nenhum dado multimodal: somente o tipo de dados de texto é compatível

Práticas recomendadas

Comece devagar

- Comece com 100 a 200 exemplos
- Valide a exatidão da função de recompensa

- Escale gradualmente com base nos resultados

Avaliação pré-treinamento

- Teste o desempenho do modelo de linha de base antes do RFT
- Se as recompensas forem consistentemente de 0%, use o SFT primeiro para estabelecer as capacidades básicas
- Se as recompensas forem >95%, o RFT poderá ser desnecessário

Monitorar o treinamento

- Acompanhe as pontuações médias e a distribuição das recompensas
- Observe o sobreajuste (as recompensas de treinamento aumentam enquanto as recompensas de validação diminuem)
- Procure padrões de atenção:
 - Recompensas se estabilizando abaixo de 0,15
 - Aumento da variação da recompensa ao longo do tempo
 - Queda no desempenho de validação

Otimizar as funções de recompensa

- Execute em segundos (não em minutos)
- Minimize as chamadas de API externas
- Use algoritmos eficientes
- Implemente o tratamento adequado de erros
- Aproveite as vantagens da escalabilidade paralela do Lambda

Estratégia de iteração

Se as recompensas não estiverem melhorando:

- Ajuste o design da função de recompensa
- Aprimore a diversidade do conjunto de dados
- Adicione mais exemplos representativos

- Verifique se os sinais de recompensa são claros e consistentes

Recursos avançados: Nova Forge

Para usuários que precisam de recursos avançados além das limitações padrão do RFT, o Nova Forge está disponível como uma oferta de serviço de assinatura paga:

- Compatível com conversa de vários turnos
- Funções de recompensa com mais de 15 minutos de tempo de execução
- Algoritmos adicionais e opções de ajuste
- Modificações personalizadas das fórmulas de treinamento
- Técnicas de IA de última geração

O Nova Forge é executado no SageMaker HyperPod e foi projetado para ajudar clientes empresariais a criar seus próprios modelos de fronteira.

Comandos e dicas úteis

Uma coleção de [scripts de observabilidade](#) está disponível para ajudar a monitorar o status e o progresso das tarefas de treinamento.

Os scripts disponíveis são:

- Habilitar notificações por e-mail para atualizações do status da tarefa de treinamento
- Obter estimativas de tempo de treinamento com base nas configurações da tarefa
- Obter estimativas da duração do treinamento para tarefas em andamento

Instalação

Note

Certifique-se de atualizar suas credenciais da AWS antes de usar qualquer um dos scripts a seguir.

```
pip install boto3
```

```
git clone https://github.com/aws-samples/amazon-nova-samples.git
cd amazon-nova-samples/customization/SageMakerUtils/SageMakerJobsMonitoring/
```

Uso básico

```
# 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
```

Consulte [aqui](#) para obter mais detalhes e exemplos.

Monitoramento do progresso em todas as iterações



Você pode acompanhar as métricas por meio do MLflow.

Personalização do Nova: configuração do MLFlow para o SageMaker HyperPod

Para permitir que seu ambiente do SageMaker HyperPod gere métricas para o MLflow, é necessário fazer algumas configurações adicionais.

1. Abra o Amazon SageMaker AI.
2. Selecione SageMaker Studio.
 - a. Se já houver um perfil criado, selecione “Abrir Studio”.
 - b. Se nenhum perfil tiver sido criado, selecione “Criar um domínio do SageMaker” para configurar um.

3. Selecione MLflow. Se não houver nenhuma aplicação MLflow criada, selecione “Criar aplicação MLflow”.
4. Clique no botão copiar/colar ou no item de menu “Visualizar detalhes” na aplicação MLflow para obter o ARN. Você precisará dele ao enviar sua tarefa de treinamento.



5. No perfil de execução do cluster do HyperPod, adicione a política a seguir. Isso permitirá que o cluster do HyperPod chame a API do MLflow para publicar métricas.

```
{
  "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": "*"
    }
  ]
}
```

Envio de uma tarefa por meio da CLI

Especifique quatro novos parâmetros de substituição na linha de comando ou na fórmula YAML.

1. `mlflow_tracking_uri`: o ARN da aplicação MLflow
2. `mlflow_experiment_name`: o nome para esta execução do experimento
3. `mlflow_experiment_name`: o nome do experimento em que as métricas serão armazenadas no MLflow
4. `mlflow_run_name`: o nome desse experimento

Linha de 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"
```

Envio de uma tarefa por meio da interface do usuário do SageMaker Studio

A integração com o MLflow já está incorporada à experiência da interface do usuário do SageMaker Studio. Ao enviar uma tarefa de treinamento, basta indicar qual instância da aplicação MLflow usar.

1. No SageMaker Studio, navegue até Modelos > Nova 2.0 Lite > Personalizar > Personalizar com a interface do usuário.
2. Expanda a seção Configuração avançada.

3. Selecione a aplicação MLflow para a qual você gostaria de enviar as métricas de treinamento. Você também pode definir o nome e a execução do experimento aqui.

MLflow

MLflow Resource *
 MLflow resource selected for experiment tracking.

DefaultMLFlowApp

Experiment name
 Default name applied. Enter a new name if desired.

myuser-sft-lora-exp1

Experiment run
 The run name is autogenerated by default. Specify a new name if desired.

myuser-sft-lora-exp1-1766499113356

Envio de uma tarefa por meio da AWS AWS CLI

Se você usar a AWS AWS CLI, deverá criar uma aplicação MLflow e passá-la como uma entrada para a solicitação da API da tarefa de treinamento.

```
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)
```

Criar uma aplicação MLflow

Usando a interface do usuário do Studio: se você criar uma tarefa de treinamento por meio da interface do usuário do Studio, uma aplicação MLflow padrão será criada automaticamente e estará selecionada por padrão em Opções avançadas.

Usando a CLI: se você usar a CLI, deverá criar uma aplicação MLflow e passá-la como uma entrada para a solicitação da API da tarefa de treinamento.

```
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)
```

Acessar a aplicação MLflow

Usando a CLI: crie um URL pré-assinado para acessar a interface do usuário da aplicação MLflow:

```
aws sagemaker create-presigned-mlflow-app-url \
  --arn $mlflow_app_arn \
  --region $region \
  --output text
```

Usando a interface do usuário do Studio: a interface do usuário do Studio exibe as principais métricas armazenadas no MLflow e fornece um link para a interface do usuário da aplicação MLflow.

Principais métricas a serem acompanhadas

Monitore essas métricas em todas as iterações para avaliar a melhoria e acompanhar o progresso da tarefa:

No SFT

- Curvas de perda de treinamento
- Número de amostras consumidas e tempo para processar amostras
- Precisão de performance em conjuntos de teste retidos
- Conformidade de formato (p. ex., taxa de saída JSON válida)
- Perplexidade nos dados de avaliação específicos do domínio

No RFT

- Pontuações médias de recompensa em relação ao treinamento
- Distribuição de recompensas (porcentagem de respostas de alta recompensa)
- Tendências de recompensa de validação (observe se há ajustes excessivos)
- Taxas de sucesso específicas de tarefas (p. ex., taxa de aprovação de execução de código, precisão de problemas matemáticos)

Geral

- Avaliação comparativa dos deltas de performance entre as iterações
- Pontuações de avaliação humana em amostras representativas
- Métricas de produção (se implantadas de forma iterativa)

Determinação de quando parar

Pare de iterar quando:

- Estagnação da performance: o treinamento adicional não melhora mais significativamente as métricas-alvo
- Trocar de técnica ajuda: se uma técnica estagnar, tente alternar (p. ex., SFT → RFT → SFT) para ultrapassar os limites de performance
- Métricas-alvo alcançadas: seus critérios de sucesso foram atendidos
- Regressão detectada: novas iterações degradam a performance (consulte os procedimentos de reversão abaixo)

Para obter procedimentos de avaliação detalhados, consulte a seção Avaliação.

Avaliar o modelo treinado do SageMaker AI

O objetivo do processo de avaliação é avaliar o desempenho do modelo treinado em relação a referências ou conjuntos de dados personalizados. O processo de avaliação geralmente envolve etapas para criar uma fórmula de avaliação apontando para o modelo treinado, especificar conjuntos de dados e métricas de avaliação, enviar um trabalho separado para avaliação e avaliar com base em referências padrão ou dados personalizados. O processo de avaliação gerará métricas de desempenho armazenadas no bucket do Amazon S3.

 Note

O processo de avaliação descrito neste tópico é um processo off-line. O modelo é testado em relação a referências fixas com respostas predefinidas, em vez de ser avaliado em tempo real ou por meio de interações ao vivo com o usuário. Para avaliação em tempo real, você pode testar o modelo depois de implantado no Amazon Bedrock chamando as APIs de runtime do [Amazon Bedrock](#).

Tópicos

- [Pré-requisitos](#)
- [Tarefas de referência disponíveis](#)
- [Configurações específicas de avaliação](#)
- [Executar tarefas de treinamento de avaliação](#)
- [Avaliar e analisar os resultados da avaliação](#)
- [Práticas recomendadas e solução de problemas de avaliação](#)
- [Subtarefas disponíveis](#)
- [Avaliação de modelo de raciocínio](#)
- [Avaliação de RFT](#)
- [Implementação de funções de recompensa](#)

Pré-requisitos

Antes de iniciar uma tarefa de treinamento de avaliação, observe o seguinte:

- Um modelo do Amazon Nova treinado pelo SageMaker AI que você deseja avaliar o desempenho.
- Fórmula básica do Amazon Nova para avaliação. Para obter mais informações, consulte [???](#).

Tarefas de referência disponíveis

Um pacote de código de amostra está disponível para demonstrar como calcular métricas de referência usando o recurso de avaliação de modelo do SageMaker AI para o Amazon Nova. Para acessar os pacotes de código, consulte [sample-Nova-ligtheval-custom-task](#).

Veja aqui uma lista de referências padrão do setor disponíveis e compatíveis. É possível especificar as referências a seguir no parâmetro `eval_task`.

Referências disponíveis para avaliação de modelo

Referência	Modalidade	Descrição	Métricas	Estratégia	Subtarefa disponível
mmlu	Texto	Compreensão de linguagem multitarefa: testa o conhecimento em 57 disciplinas.	accuracy	zs_cot	Sim
mmlu_pro	Texto	MMLU (subconjunto profissional): concentra-se em domínios profissionais como direito, medicina, contabilidade e engenharia.	accuracy	zs_cot	Não
bbh	Texto	Tarefas de raciocínio avançado: um conjunto de problemas desafiadores que testam habilidades cognitivas e de resolução	accuracy	fs_cot	Sim

Referência	Modalidade	Descrição	Métricas	Estratégia	Subtarefa disponível
		de problemas de nível mais alto.			
gpqa	Texto	Resposta a perguntas de física geral: avalia a compreensão de conceitos de física e habilidades relacionadas à resolução de problemas .	accuracy	zs_cot	Não
math	Texto	Resolução de problemas matemáticos: mede o raciocínio matemático em vários tópicos, como álgebra, cálculo e problemas de palavras.	exact_match	zs_cot	Sim

Referência	Modalidade	Descrição	Métricas	Estratégia	Subtarefa disponível
strong_reject	Texto	Tarefa de controle de qualidade : testa a capacidade do modelo de detectar e rejeitar conteúdo impróprio, prejudicial ou incorreto.	deflection	zs	Sim
ifeval	Texto	Avaliação de seguimento de instruções: avalia com que precisão um modelo segue as instruções dadas e conclui as tarefas conforme as especificações.	accuracy	zs	Não

Referência	Modalidade	Descrição	Métricas	Estratégia	Subtarefa disponível
gen_qa	Multimodal (imagem)	Avaliação personalizada do conjunto de dados: permite que você forneça seu próprio conjunto de dados para avaliação comparativa, comparando as saídas dos modelos para as respostas de referência com métricas como ROUGE e BLEU. gen_qa é compatível com a inferência de imagens para modelos baseados no Amazon Nova Lite e no Amazon Nova Pro. Também	todas	gen_qa	Não

Referência	Modalidade	Descrição	Métricas	Estratégia	Subtarefa disponível
		permite o uso de perfis do lambda para métricas personalizadas. (Para avaliação de RFT, use a fórmula de avaliação de RFT)			
mmmu	Multimodal	Massive Multidiscipline Multimodal Understanding (MMMU): avaliação comparativa de nível universitário que compreende perguntas abertas e de múltipla escolha de 30 disciplinas.	accuracy	zs_cot	Sim

Referência	Modalidade	Descrição	Métricas	Estratégia	Subtarefa disponível
llm_judge	Texto	Comparação de preferências do LLM como avaliador : usa um modelo avaliador do Nova para determinar a preferência entre respostas emparelhadas (B em comparação com A) para os prompts, calculando a probabilidade de B ser preferida em relação a A.	todas	avaliador	Não

Referência	Modalidade	Descrição	Métricas	Estratégia	Subtarefa disponível
mm_llm_judge	Multimodal (imagem)	Esta nova avaliação comparativa se comporta da mesma forma que o llm_judge baseado em texto acima. A única diferença é que ele é compatível com a inferência de imagens.	todas	avaliador	Não

Referência	Modalidade	Descrição	Métricas	Estratégia	Subtarefa disponível
rubric_llm_judge	Texto	O Rubric Judge é um modelo aprimorado de avaliação LLM como avaliador criado no Nova 2.0 Lite. Ao contrário do modelo original do avaliador , que fornece apenas veredictos preferenciais, o Rubric Judge gera dinamicamente critérios de avaliação personalizados para cada prompt e atribui pontuações granulares em várias dimensões.	todas	avaliador	Não

Referência	Modalidade	Descrição	Métricas	Estratégia	Subtarefa disponível
aime_2024	Texto	AIME 2024: problemas do American Invitational Mathematics Examination que testam raciocínio matemático avançado e resolução de problemas	exact_match	zs_cot	Não
calendar_scheduling	Texto	Natural Plan: agendamento de calendário, tarefa de teste de habilidades de planejamento para marcar reuniões de vários dias e com várias pessoas	exact_match	fs	Não

Referência	Modalidade	Descrição	Métricas	Estratégia	Subtarefa disponível
humaneval	Texto	HumanEval: um conjunto de dados de referência projetado para avaliar as capacidades de geração de código de grandes modelos de linguagem.	passar@1	zs	Não

Configurações específicas de avaliação

Abaixo é apresentado um detalhamento dos principais componentes na fórmula e orientações sobre como modificá-los para seus casos de uso.

Informações sobre as fórmulas e sobre como modificá-las

Configuração geral de execução

```
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: um nome descritivo para sua tarefa de avaliação.

- `model_type`: especifica a variante do modelo do Nova a ser usada. Não modifique manualmente esse campo. Entre as opções estão:
 - `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`: o caminho para o modelo de base ou caminho do S3 para o ponto de verificação pós-treinado. Entre as opções estão:
 - `nova-micro/prod`
 - `nova-lite/prod`
 - `nova-pro/prod`
 - `nova-lite-2/prod`
 - Caminho do S3 para o caminho do ponto de verificação pós-treinado (`s3:customer-escrow-111122223333-smtj-<unique_id>/<training_run_name>`)

 Note

Avaliar modelo pós-treinado

Para avaliar um modelo pós-treinado após uma tarefa de treinamento de SFT do Nova, siga estas etapas após executar uma tarefa de treinamento bem-sucedida. No final dos logs de treinamento, você verá a mensagem de log “Training is complete”. Você também encontrará um arquivo `manifest.json` no bucket de saída que contém o local do ponto de verificação. Esse arquivo estará localizado dentro de um arquivo `output.tar.gz` no local de saída do S3. Para continuar com a avaliação, use esse ponto de verificação definindo-o como o valor para `run.model_name_or_path` na configuração da sua fórmula.

- `replica`: o número de instâncias de computação a serem usadas para inferência distribuída (execução de inferência em vários nós). Defina `replica > 1` para permitir a inferência de vários nós, o que acelera a avaliação. Se `instance_count` e `replica` forem especificados, `instance_count` terá precedência. Observe que várias réplicas só se aplicam às tarefas de treinamento do SageMaker AI.
- `data_s3_path`: o caminho do Amazon S3 do conjunto de dados de entrada. Esse campo é obrigatório, mas sempre deve ser deixado em branco.

- `mlflow_tracking_uri`: (opcional) a localização do servidor de rastreamento MLflow (necessário somente no SMHP)
- `mlflow_experiment_name`: (opcional) nome do experimento para agrupar execuções de ML relacionadas
- `mlflow_run_name`: (opcional) nome personalizado para um treinamento específico executado em um experimento

Configuração da avaliação

```
evaluation:  
  task: mmlu  
  strategy: zs_cot  
  subtask: abstract_algebra  
  metric: accuracy
```

- `task`: especifica a referência ou tarefa de avaliação a ser usada. As tarefas permitidas incluem:
 - `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`: define a abordagem de avaliação.

- `zs_cot`: cadeia de pensamento zero shot, uma abordagem de utilização de prompts em grandes modelos de linguagem que incentiva o raciocínio passo a passo sem exigir exemplos explícitos.
- `fs_cot`: cadeia de pensamento few shot, uma abordagem que fornece alguns exemplos de raciocínio passo a passo antes de pedir ao modelo que resolva um novo problema.
- `zs`: zero shot, uma abordagem para resolver um problema sem nenhum exemplo de treinamento prévio.
- `gen_qa`: estratégia específica para trazer seu próprio conjunto de dados.
- `jjudge`: estratégia específica para LLM Nova como avaliador e `mm_llm_judge`.
- `subtask`: opcional. Componentes específicos da tarefa de avaliação. Para ver uma lista completa de subtarefas disponíveis, consulte [???](#).
 - Verifique as subtarefas permitidas em “Tarefas de referência disponíveis”.
 - É necessário remover esse campo se não houver subtarefas de referência.
- `metric`: a métrica de avaliação a ser usada.
 - `accuracy`: porcentagem de respostas corretas.
 - `exact_match`: para a referência math, exibe a taxa na qual as strings previstas de entrada correspondem exatamente às respectivas referências.
 - `deflection`: para a referência strong reject, exibe a deflexão relativa ao modelo base e as métricas de significância da diferença.
- `all`:

Para a referência `gen_qa`, traga seu próprio conjunto de dados, exibe as seguintes métricas:

- `rouge1`: mede a sobreposição de unigramas (palavras únicas) entre o texto gerado e o texto de referência.
- `rouge2`: mede a sobreposição de bigramas (duas palavras consecutivas) entre o texto gerado e o texto de referência.
- `rougeL`: mede a maior subsequência comum entre textos, permitindo lacunas na correspondência.
- `exact_match`: pontuação binária (0 ou 1) indicando se o texto gerado corresponde exatamente ao texto de referência, caractere por caractere.
- `quasi_exact_match`: semelhante à correspondência exata, mas mais tolerante. Geralmente ignora diferenças de maiúsculas e minúsculas, pontuação e espaço em branco.

- `f1_score`: média harmônica de precisão e recall. Mede a sobreposição de palavras entre as respostas previstas e de referência.
- `f1_score_quasi`: semelhante ao `f1_score`, mas com uma correspondência mais branda. Usa a comparação de texto normalizada que ignora pequenas diferenças.
- `bleu`: mede a precisão das correspondências de n-gramas entre o texto gerado e o texto de referência. É comumente usada em avaliação de tradução.

Para `llm_judge` e `mm_llm_judge`, utilize seu próprio conjunto de dados de avaliação comparativa e obtenha as seguintes métricas:

- `a_scores`: número de acertos da `response_A` em passagens de avaliação para frente e para trás.
- `a_scores_stderr`: erro padrão de `response_A_scores` em avaliações de pares.
- `b_scores`: mede o número de acertos da `response_B` em passes de avaliação para frente e para trás.
- `a_scores_stderr`: erro padrão de `response_B_scores` em avaliações de pares.
- `ties`: número de avaliações em que a `response_A` e a `response_B` são avaliadas como iguais.
- `ties_stderr`: erro padrão de `ties` em avaliações de pares.
- `inference_error`: contagem de avaliações que não puderam ser concluídas adequadamente.
- `score`: pontuação agregada com base nos acertos dos passes para frente e para trás da `response_B`.
- `score_stderr`: pontuação agregada com base nos acertos dos passes para frente e para trás da `response_B`.
- `inference_error_stderr`: erro padrão da pontuação agregada em avaliações de pares.
- `winrate`: a probabilidade de que a `response_B` será preferida em relação à `response_A` calculada por meio da probabilidade de Bradley-Terry.
- `lower_rate`: limite inferior (2,5º percentil) da taxa de acerto estimada da amostragem de bootstrap.
- `upper_rate`: limite inferior (97,5º percentil) da taxa de acerto estimada da amostragem de bootstrap.

Configuração de inferência (opcional)


```
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`: número máximo de tokens a serem gerados. Deve ser um número inteiro. (Indisponível para LLM como avaliador.)
- `top_k`: número de tokens de maior probabilidade a serem considerados. Deve ser um número inteiro.
- `top_p`: limite de probabilidade cumulativa para a amostragem de tokens. Deve ser um número de ponto flutuante entre 1,0 e 0,0.
- `temperature`: aleatoriedade na seleção de tokens (maior = mais aleatório). Mantenha 0 que o resultado seja determinístico. Tipo flutuante. O valor mínimo é 0.
- `top_logprobs`: o número dos principais logprobs a serem retornados na resposta de inferência. O valor deve ser um número inteiro de 0 a 20. Os logprobs contêm os tokens de saída considerados e as probabilidades logarítmicas de cada token de saída retornado no conteúdo da mensagem.
- `reasoning_effort`: controla o comportamento de raciocínio para modelos capazes de raciocinar. Defina `reasoning_effort` somente quando `model_type` especificar um modelo capaz de raciocínio (atualmente `amazon.nova-2-lite-v1:0:256k`). As opções disponíveis são `null` (valor padrão se não definido; desabilita o raciocínio), `low` ou `high`.

Formato de saída da probabilidade logarítmica

Quando `top_logprobs` está configurado em suas definições de inferência, o resultado da avaliação inclui probabilidades logarítmicas em nível de token nos arquivos parquet. Cada posição de token contém um dicionário dos principais tokens candidatos com suas probabilidades logarítmicas na seguinte estrutura:

```
{
  "Ġint": {"logprob_value": -17.8125, "decoded_value": " int"},
  "Ġthe": {"logprob_value": -2.345, "decoded_value": " the"}
}
```

Cada entrada de token contém:

- `logprob_value`: o valor da probabilidade logarítmica para o token
- `decoded_value`: a representação de string decodificada legível por humanos do token

O token bruto do tokenizador é usado como a chave do dicionário para garantir a exclusividade, enquanto `decoded_value` fornece uma interpretação legível.

Exemplos de fórmula de avaliação

O Amazon Nova oferece quatro tipos diferentes de fórmula de avaliação. Todas as fórmulas estão disponíveis no [repositório de fórmulas do SageMaker HyperPod no GitHub](#).

Fórmulas gerais de referência de texto

Essas fórmulas permitem que você avalie as capacidades fundamentais dos modelos do Amazon Nova em um conjunto abrangente de referências somente de texto.

Formato da fórmula: `xxx_general_text_benchmark_eval.yaml`.

Fórmulas de referência de traga seu próprio conjunto de dados

Essas fórmulas permitem que você traga seu próprio conjunto de dados para fins de avaliação comparativa e compare os resultados do modelo com as respostas de referência usando diferentes tipos de métrica.

Formato da fórmula: `xxx_bring_your_own_dataset_eval.yaml`.

Traga seus próprios requisitos de conjunto de dados

Formato do arquivo:

- Um único arquivo `gen_qa.jsonl` contendo exemplos de avaliação. O nome do arquivo deve ser exatamente `gen_qa.jsonl`.
- Você deve fazer o upload de seu conjunto de dados em um local do S3 que as tarefas de treinamento do SageMaker AI possam acessar.
- O arquivo deve seguir o formato de esquema exigido para um conjunto de dados geral de perguntas e respostas.

Exigências do formato do esquema: cada linha no arquivo `.jsonl` deve ser um objeto JSON com os campos a seguir.

- Campos obrigatórios.

`query`: string contendo a pergunta ou instrução que precisa de uma resposta.

`response`: string contendo a saída esperada do modelo.

- Campos opcionais.

`system`: string contendo o prompt do sistema que define o comportamento, o perfil ou a personalidade do modelo de IA antes de processar a consulta.

`images`: matriz contendo uma lista de objetos com atributos de dados (strings de imagens codificadas em Base64).

`metadata`: string contendo metadados associados à entrada para fins de marcação.

Exemplo de entrada

```
{
  "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 ..."
```

```
}  
]  
}
```

Para usar seu conjunto de dados personalizado, modifique sua fórmula de avaliação adicionando os campos obrigatórios abaixo sem alterar a configuração existente:

```
evaluation:  
  task: gen_qa  
  strategy: gen_qa  
  metric: all
```

Limitações

- Somente um arquivo `.jsonl` é permitido por avaliação.
- O arquivo deve seguir rigorosamente o esquema definido.

Trazar suas próprias métricas

Você pode trazer suas próprias métricas para personalizar totalmente seu fluxo de trabalho de avaliação de modelos com recursos personalizados de pré-processamento, pós-processamento e métricas. O pré-processamento permite que você processe os dados de entrada antes de enviá-los ao servidor de inferência, e o pós-processamento permite que você personalize o cálculo das métricas e retorne métricas personalizadas com base nas suas necessidades.

Siga estas etapas para criar suas próprias métricas com o SDK de avaliação personalizado.

1. Caso ainda não tenha feito isso, [crie uma função do AWS Lambda](#) na sua primeira Conta da AWS.
2. Faça o download do arquivo `nova-custom-eval-layer.zip` pré-criado do [repositório do GitHub](#). Você pode usar esse SDK de avaliação personalizada de código aberto do Nova para validar as cargas úteis de entrada e saída de sua função personalizada e fornecer uma interface unificada para integração com a avaliação de traga suas próprias métricas do Nova durante o treinamento.
3. Faça o upload da camada do Lambda personalizada usando o seguinte 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. Adicione essa camada como uma camada personalizada à sua função do Lambda, junto com a camada necessária da AWS: `AWSLambdaPowerToolsPythonV3-python312-arm64` (necessária para a dependência `pydantic`).
5. Atualize seu código do Lambda usando o exemplo fornecido, modificando o código conforme necessário. Esse código de exemplo cria uma função do Lambda para a avaliação personalizada do Nova com etapas de pré-processamento e pós-processamento para a avaliação de modelo.

```
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. Conceda ao Lambda acesso à tarefa de avaliação. Certifique-se de que o perfil de execução especificado para a tarefa de avaliação inclua uma política para invocar sua função do Lambda. Veja a seguir um exemplo de política:

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. Analise o esquema de carga útil do Lambda. A tabela a seguir lista o esquema de solicitação e resposta do Lambda. Você pode validar seu esquema usando o SDK de avaliação personalizada do Nova.

	Carga útil de solicitação do Lambda	Carga útil de resposta do Lambda
Pré-proc ssador	<pre>{ "process_type": "preproce ss", "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>
Pós-proce ssador	<pre>{ "process_type": "postproc ess", "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>

	Carga útil de solicitação do Lambda	Carga útil de resposta do Lambda
		<pre>] }</pre>

8. Modifique o arquivo da fórmula. Aqui está um exemplo.

```

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`: o nome do recurso da Amazon (ARN) para sua função do Lambda que lida com o pré-processamento e pós-processamento.
- `lambda_type`: “custom_metrics” ou “rft”.
- `preprocessing`: se as operações de pré-processamento personalizadas devem ser habilitadas.
- `postprocessing`: se as operações de pós-processamento personalizadas devem ser habilitadas.
- `aggregation`: função de agregação integrada (opções válidas: mínimo, máximo, média, soma).

Limitações

- Traga suas próprias métricas só se aplica a conjuntos de dados de entrada de texto.
- Não há suporte para conjuntos de dados de entrada multimodais.
- A etapa de pré-processamento não processa o campo de metadados.

Fórmulas de referência de LLM como avaliador do Nova

O LLM como avaliador do Nova é um recurso de avaliação de modelo que permite que você compare a qualidade das respostas de um modelo com a resposta de um modelo de referência em um conjunto de dados personalizado. Ele aceita um conjunto de dados contendo prompts, respostas

de referência e respostas do contestador e usa um modelo avaliador do Nova para fornecer uma métrica de taxa de acertos com base na [probabilidade de Bradley-Terry](#) por meio de comparações de pares. Formato da fórmula: `xxx_llm_judge_eval.yaml`.

Requisitos do conjunto de dados do LLM do Nova

Formato do arquivo:

- Um único arquivo `llm_judge.jsonl` contendo exemplos de avaliação. O nome do arquivo deve ser exatamente `llm_judge.jsonl`.
- Você deve fazer o upload de seu conjunto de dados em um local do S3 que as tarefas de treinamento do SageMaker AI possam acessar.
- O arquivo deve seguir o formato de esquema exigido para o conjunto de dados `llm_judge`.
- O conjunto de dados de entrada deve garantir que todos os registros tenham menos de 12 mil de comprimento de contexto.

Formato do esquema: cada linha no arquivo `.jsonl` deve ser um objeto JSON com os campos a seguir.

- Campos obrigatórios.

`prompt`: string contendo o prompt para a resposta gerada.

`response_A`: string contendo a resposta de referência.

`response_B`: string contendo a resposta alternativa a ser comparada com a resposta de referência.

Exemplo de entrada

```
{
  "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."
}
```

Para usar seu conjunto de dados personalizado, modifique a fórmula de avaliação com os campos obrigatórios a seguir. Não altere nenhum conteúdo.

```
evaluation:
  task: llm_judge
  strategy: judge
  metric: all
```

Limitações

- Somente um arquivo `.jsonl` é permitido por avaliação.
- O arquivo deve seguir rigorosamente o esquema definido.
- Os modelos avaliadores do Nova são os mesmos nas especificações Micro/Lite/Pro.
- No momento, não há compatibilidade para modelos avaliadores.

LLM como avaliador do Nova para fórmulas de avaliações comparativas multimodais (imagem)

O LLM como avaliador do Nova para multimodais (imagem), ou simplesmente Nova MM_LLM Judge, é um recurso de avaliação de modelos que permite que você compare a qualidade das respostas de um modelo com as respostas de um modelo de linha de base usando um conjunto de dados personalizado. Ele aceita um conjunto de dados contendo prompts, respostas de

linha de base, respostas do desafiante e imagens no formato de string codificada em Base64, e depois usa um modelo avaliador do Nova para fornecer uma métrica de taxa de acertos com base na probabilidade de [Bradley-Terry](#) por meio de comparações de pares. Formato da fórmula: `xxx_mm_llm_judge_eval.yaml`.

Requisitos do conjunto de dados do LLM do Nova

Formato do arquivo:

- Um único arquivo `mm_llm_judge.jsonl` contendo exemplos de avaliação. O nome do arquivo deve ser exatamente `llm_judge.jsonl`.
- Você deve fazer o upload de seu conjunto de dados em um local do S3 que as tarefas de treinamento do SageMaker AI possam acessar.
- O arquivo deve seguir o formato de esquema exigido para o conjunto de dados `mm_llm_judge`.
- O conjunto de dados de entrada deve garantir que todos os registros estejam dentro do limite de 12 mil de contexto, excluindo o atributo da imagem.

Formato do esquema: cada linha no arquivo `.jsonl` deve ser um objeto JSON com os campos a seguir.

- Campos obrigatórios.

`prompt`: string contendo o prompt para a resposta gerada.

`images`: matriz contendo uma lista de objetos com atributos de dados (os valores são strings de imagens codificadas em Base64).

`response_A`: string contendo a resposta de referência.

`response_B`: string contendo a resposta alternativa a ser comparada com a resposta de referência.

Exemplo de entrada

Para facilitar a leitura, o exemplo a seguir inclui novas linhas e recuo, mas no conjunto de dados real, cada registro deve estar em uma única linha.

```
{
  "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"
}

```

Para usar seu conjunto de dados personalizado, modifique a fórmula de avaliação com os campos obrigatórios a seguir. Não altere nenhum conteúdo.

```

evaluation:
  task: mm_llm_judge
  strategy: judge
  metric: all

```

Limitações

- Somente um arquivo `.jsonl` é permitido por avaliação.
- O arquivo deve seguir rigorosamente o esquema definido.
- Os modelos Nova MM Judge são compatíveis apenas com a referência de imagem.
- Os modelos Nova MM Judge são iguais nas especificações do Amazon Nova Micro, Amazon Nova Lite e Amazon Nova Pro.
- No momento, não há compatibilidade para modelos avaliadores.
- O URI de imagem do Amazon S3 não é compatível.

- O conjunto de dados de entrada deve garantir que todos os registros estejam dentro do limite de 12 mil de contexto, excluindo o atributo de imagens.

Avaliação dos pontos de verificação de CPT (pré-treinamento contínuo)

A avaliação de modelos CPT (pré-treinados continuamente) pode ser mais desafiadora do que modelos que foram submetidos ao SFT (ajuste fino supervisionado), pois os modelos CPT geralmente não têm a capacidade de seguir as instruções. Em vez de seguir as instruções, o modelo CPT funcionará como modelos de conclusão, o que significa que eles apenas tentarão continuar o padrão fornecido com a sequência do token de entrada. Devido a essa limitação, conjuntos de dados de avaliação típicos podem não funcionar corretamente por causa do formato de “perguntas e respostas” das entradas. Em vez de responder à pergunta, o modelo simplesmente tentará continuar com a mesma pergunta. No entanto, ao formatar conjuntos de dados de uma forma específica para gerar prompts para os modelos em um estilo de preenchimento, podemos entender o desempenho do modelo.

Siga as etapas abaixo para entender como realizar uma avaliação em um modelo pré-treinado contínuo usando o fluxo de trabalho de avaliação do Nova Forge.

Preparação e formatação do conjunto de dados

A avaliação de um modelo CPT aproveita o fluxo de trabalho de [Traga seu próprio dispositivo](#) já existente, fornecido na experiência de avaliação de modelos do Nova Forge. No entanto, as consultas em um conjunto de dados devem ser formatadas em um formato puramente de “conclusão”, pois os modelos CPT não responderão aos prompts de estilo de pergunta padrão da mesma forma que um modelo SFT faria.

Outra limitação frequente importante de modelos que foram submetidos exclusivamente ao CPT é sua incapacidade de gerar tokens de PARADA ou de fim de sequência. Isso significa que o modelo continuará a gerar tokens até ser interrompido à força (como com o parâmetro `max_new_tokens`). Devido a essa limitação, a prática recomendada é avaliar os modelos usando respostas de token único (como múltipla escolha) para garantir que o modelo não continue a gerar resultados irrelevantes que não são necessários após a geração de prompts.

Por exemplo, um conjunto de dados de avaliação típico (como MMLU, GPQA, MATH etc.) pode fazer com que o modelo faça uma pergunta como:

```
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.)

No entanto, um modelo CPT não entenderia como responder adequadamente a essa pergunta devido à falta de ajuste fino na instrução a seguir. Portanto, os modelos CPT devem receber prompts em um estilo de preenchimento, como:

```
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.)

Após a verificação da inferência, as logprobs de saída geradas pelo modelo fornecerão detalhes sobre se o modelo estava processando corretamente a entrada e gerando a resposta correta. Não há garantia de que o modelo sempre gere a resposta exata (neste caso, a letra D) esperada, no entanto, ela deverá estar presente nas logprobs se o modelo estiver funcionando corretamente.

Outro exemplo de prompt de estilo de preenchimento, sem ser de múltipla escolha:

```
The capital of France is
```

(Expected answer of Paris)

Nós esperamos que o modelo gere uma resposta “Paris” ou veja o token correspondente a “Paris” em algum lugar na saída das logprobs.

Formato do conjunto de dados

A avaliação do CPT aproveita o fluxo de trabalho existente de [Traga seu próprio conjunto de dados](#). Os dados devem ser formatados no formato “resposta à consulta” em um arquivo JSONL separado por novas linhas.

Um exemplo de um conjunto de dados com quatro entradas:

```
{"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"}
```

Cada linha deve conter:

- query: o texto do prompt para conclusão
- response: a conclusão esperada (verdade fundamental)

O modelo receberá uma entrada de texto bruto sem formatação de bate-papo. Normalmente, os modelos CPT ainda não são treinados em tokens especiais e não respondem adequadamente aos modelos de bate-papo. Portanto, ao gerar prompts para o modelo, SOMENTE a string fornecida na consulta será enviada ao modelo (com um token [BOS] adicional anexado automaticamente).

Configuração de fórmula

Confira um exemplo de uma fórmula configurada para avaliar um modelo 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
```

Principais mudanças na avaliação do CPT:

- checkpoint_is_instruction_tuned: "false"

Este é um novo parâmetro adicionado especificamente para ser compatível com as execuções de avaliação em pontos de verificação do CPT. Definir `checkpoint_is_instruction_tuned` como `false` desabilitará o modelo de bate-papo padrão do Amazon Nova, que normalmente envolve o prompt de entrada.

- `top_logprobs`: 5

As probabilidades de log (logprobs) revelam a distribuição de confiança do modelo entre os possíveis próximos tokens, ajudando a avaliar se o modelo aprendeu as conclusões esperadas durante o pré-treinamento. Normalmente, se o modelo estiver funcionando conforme o esperado, devemos ver a resposta esperada (ou seja, “A”, “B” etc.) como um token de saída gerado ou um token nas logprobs.

- `max_new_tokens`: 1

Os modelos CPT normalmente ainda não foram treinados para gerar tokens especiais de “parada” ou “fim da sequência” para sinalizar quando interromper a inferência. Isso significa que o modelo normalmente continuará gerando novos tokens até que o limite máximo de tokens seja atingido, resultando em uma inferência desnecessária. Normalmente, limitar o `max_new_tokens` a 1 e fornecer um prompt que possa avaliar o modelo em uma única resposta (como uma pergunta de múltipla escolha) é a maneira mais eficiente de gerar prompts para o modelo. Definir `max_new_tokens` como 1 garante que tokens extras irrelevantes não sejam gerados.

Principais parâmetros

- `checkpoint_is_instruction_tuned`: deve ser definido como `"false"` (ou `false` como booleano) para desabilitar os modelos de bate-papo
- `top_logprobs`: 5, recomendado para ver como o modelo está aprendendo durante o CPT
- `task`: deve ser `gen_qa` - os modelos CPT não podem usar benchmarks que seguem instruções, como MMLU ou MATH
- `strategy`: deve ser `gen_qa`
- `max_new_tokens`: é recomendável manter um valor baixo (1 a 5), pois os modelos CPT realizam a conclusão, não a geração

Executar tarefas de treinamento de avaliação

Inicie uma tarefa de treinamento usando o exemplo de caderno a seguir. Consulte o caderno abaixo como exemplo para executar a tarefa de treinamento de avaliação. Para ter mais informações, consulte [Usar um estimador do SageMaker AI para executar uma tarefa de treinamento](#).

Tabelas de referência

Antes de executar o caderno, consulte as tabelas de referência a seguir para selecionar o URI da imagem e as configurações de instância.

Selecionar o URI da imagem

Fórmula	URI da imagem
URI da imagem de avaliação	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-TJ-Eval-V2-latest

Selecionar o tipo e da contagem de instâncias

Modelo	Tipo de trabalho	Tipo de instância	Contagem de instâncias recomendada	Contagem de instâncias permitidas
Amazon Nova Micro	Avaliação (SFT/DPO)	g5.12xlarge	1	1 a 16
Amazon Nova Lite	Avaliação (SFT/DPO)	g5.12xlarge	1	1 a 16
Amazon Nova Pro	Avaliação (SFT/DPO)	p5.48xlarge	1	1 a 16

Exemplo de bloco de notas

O exemplo de caderno a seguir demonstra como executar uma tarefa de treinamento de avaliação.

```
# 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})

```

Avaliar e analisar os resultados da avaliação

Após a conclusão bem-sucedida do seu trabalho de avaliação, você poderá avaliar e analisar os resultados usando as etapas a seguir.

Para avaliar e analisar os resultados, siga as etapas abaixo.

1. Entenda a estrutura do local de saída. Os resultados são armazenados no local de saída especificado do Amazon S3 como um arquivo compactado:

```

s3://your-bucket/output/benchmark-name/
### job_name/
    ### output/
        ### output.tar.gz

```

2. Baixe o arquivo `output.tar.gz` em seu bucket. Extraia o conteúdo a ser exibido.

```

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`: arquivo JSON de métricas de saída.

- `details_<task_name>_#_<datetime>.parquet`: arquivo de saída de inferência (exceto para `strong_reject`).
 - `events.out.tfevents.[timestamp]`: arquivo de saída do TensorBoard.
 - `inference_output.jsonl`: arquivo de saída de inferência limpo (somente para tarefas de `gen_qa`).
3. Visualize os resultados no TensorBoard. Para visualizar suas métricas de avaliação:
1. Faça upload da pasta extraída em um bucket do S3.
 2. Navegue até o TensorBoard no SageMaker AI
 3. Selecione “Pastas do S3”.
 4. Adicione o caminho da pasta do S3.
 5. Aguarde a conclusão da sincronização.
4. Analise os resultados da inferência. Todas as tarefas de avaliação, exceto `llm_judge` e `strong_reject`, terão os campos a seguir para análise na saída da inferência.
- `full_prompt`: o prompt completo do usuário enviado ao modelo usado para a tarefa de avaliação.
 - `gold`: o campo que contém as respostas corretas, conforme especificado pelo conjunto de dados.
 - `metrics`: o campo que contém as métricas avaliadas na inferência individual. Valores que exigem agregação não têm um valor nas saídas de inferência individuais.
 - `predictions`: o campo que contém uma lista da saída do modelo para o prompt fornecido.
 - `pred_logits`: o campo que contém os tokens de saída considerados e as probabilidades logarítmicas de cada token de saída retornado no conteúdo da mensagem.

Ao examinar esses campos, você pode determinar a causa das diferenças métricas e entender o comportamento dos modelos personalizados.

Para `llm_judge`, o arquivo de saída da inferência contém os campos a seguir no campo de métricas por par de avaliações.

- `forward_output`: as preferências brutas do avaliador ao avaliar em ordem (`response_A`, `response_B`).
- `backward_output`: as preferências brutas do avaliador ao avaliar na ordem inversa (`response_B`, `response_A`).

- **Pairwise metrics:** métricas calculadas por par de avaliações diretas e inversas, incluindo `a_scores`, `b_scores`, `ties`, `inference-score` e `score`.

 Note

Métricas agregadas, como `winrate`, estão disponíveis apenas nos arquivos de resultados resumidos, não por avaliação individual.

Para `gen_qa`, o arquivo `inference_output.jsonl` contém os seguintes campos para cada objeto JSON:

- `prompt`: o prompt final enviado ao modelo.
- `inferência`: a saída bruta de inferência do modelo.
- `gold`: a resposta esperada do conjunto de dados de entrada
- `metadata`: a string de metadados do conjunto de dados de entrada, se fornecida

Práticas recomendadas e solução de problemas de avaliação

Práticas recomendadas

A seguir estão listadas algumas das práticas recomendadas para o processo de avaliação.

- Mantenha seus caminhos de saída organizados por modelo e tipo de referência.
- Mantenha convenções de nomenclatura consistentes para facilitar o rastreamento.
- Salve os resultados extraídos em um local seguro.
- Monitore o status de sincronização do TensorBoard para garantir que os dados sejam carregados com êxito.

Solução de problemas

Você pode usar o grupo de logs `/aws/sagemaker/TrainingJobs` do CloudWatch para logs de erro de tarefa de treinamento.

Falha do núcleo do mecanismo

Problema:

Se você estiver vendo:

```
RuntimeError: Engine core initialization failed.
```

Causa:

Embora este seja um erro geral que pode ter várias causas, ele normalmente ocorre quando há uma incompatibilidade entre o ponto de verificação do modelo que você está tentando carregar e o tipo de modelo especificado. Por exemplo, você deseja avaliar um ponto de verificação do modelo Nova 2.0 Lite ajustado, mas o tipo de modelo fornecido é o tipo de modelo 1.0. Por exemplo, `amazon.nova-micro-v1:0:128k`.

O mapeamento correto deve ser

```
model_type: amazon.nova-2-lite-v1:0:256k
model_name_or_path: nova-lite-2/prod # or s3://escrow_bucket/model_location
```

Prevenção:

Verifique se `model_name_or_path` está mapeado ao `model_type` correto antes de enviar a tarefa de avaliação.

Subtarefas disponíveis

Confira abaixo as subtarefas disponíveis para avaliação de modelo em vários domínios, incluindo MMLU (Massive Multitask Language Understanding), BBH (Big Bench Hard), MATH e MMMU (Massive Multi-discipline Multimodal Understanding). Essas subtarefas permitem avaliar o desempenho do modelo em capacidades e áreas de conhecimento específicas.

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

```
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",
```

Avalie seus modelos Nova personalizados usando vários métodos e métricas de avaliação.

Nesta seção:

- [Avaliação de modelo de raciocínio](#)
- [Avaliação de RFT](#)
- [Implementação de funções de recompensa](#)

Avaliação de modelo de raciocínio

Visão geral

O suporte ao modelo de raciocínio permite a avaliação com modelos Nova capazes de raciocinar que realizam raciocínio interno explícito antes de gerar respostas finais. Esse recurso usa o controle em nível de API por meio do parâmetro `reasoning_effort` para habilitar ou desabilitar dinamicamente a funcionalidade de raciocínio, melhorando potencialmente a qualidade da resposta para tarefas analíticas complexas.

Modelos compatíveis

- `amazon.nova-2-lite-v1:0:256k`

Configuração de fórmula

Habilite o raciocínio adicionando o parâmetro `reasoning_effort` à seção `inference` da sua fórmula:

```
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)

```

Uso do parâmetro reasoning_effort

O parâmetro `reasoning_effort` controla o comportamento do raciocínio para modelos capazes de raciocinar.

Pré-requisitos

- Compatibilidade do modelo: defina `reasoning_effort` somente quando `model_type` especificar um modelo com capacidade de raciocínio. (atualmente `amazon.nova-2-lite-v1:0:256k`)
- Tratamento de erros: o uso de `reasoning_effort` com modelos não compatíveis falhará com `ConfigValidationError: "Reasoning mode is enabled but model '{model_type}' does not support reasoning. Please use a reasoning-capable model or disable reasoning mode."`

Opções disponíveis

Opção	Comportamento	Limite de tokens	Caso de uso
null (padrão)	Desabilita o modo de raciocínio	N/D	Avaliação padrão sem sobrecarga de raciocínio

Opção	Comportamento	Limite de tokens	Caso de uso
low	Permite o raciocínio com restrições	4 mil tokens para raciocínio interno	Cenários que exigem raciocínio conciso; otimiza em termos de velocidade e custo
high	Permite o raciocínio sem restrições	Nenhum limite de token no raciocínio interno	Problemas complexos que exigem análise extensiva e raciocínio passo a passo

modo de treinamento	Opções disponíveis	Como configurar
SFT (ajuste fino supervisionado)	Somente High ou Off	Use reasoning_enabled: true (high) ou reasoning_enabled: false (off)
RFT (ajuste fino por reforço)	Low, High ou Off	Use reasoning_effort: low ou reasoning_effort: high. Omita o campo a ser desabilitado.
Avaliação	Low, High ou Off	Use reasoning_effort: low ou reasoning_effort: high. Use null para desabilitar.

Quando habilitar o raciocínio

Use o modo de raciocínio (**low** ou **high**) para

- Tarefas complexas de resolução de problemas (cálculo, quebra-cabeças lógicos, codificação)
- Perguntas analíticas de várias etapas que exigem raciocínio intermediário
- Tarefas em que explicações detalhadas ou o raciocínio passo a passo melhoram a precisão
- Cenários em que a qualidade da resposta é priorizada em relação à velocidade

Use o modo sem raciocínio (**null** ou omita o parâmetro) para

- Perguntas e respostas simples ou consultas factuais
- Tarefas de escrita criativa

- Quando tempos de resposta mais rápidos são essenciais
- Avaliação comparativa de performance em que a sobrecarga de raciocínio deve ser excluída
- Otimização de custos quando o raciocínio não melhora a performance da tarefa

Solução de problemas

Erro: "o modo de raciocínio está habilitado, mas o modelo não é compatível com ele"

Causa: o parâmetro `reasoning_effort` está definido como um valor não nulo, mas o `model_type` especificado não é compatível com o raciocínio.

Resolução:

- Verifique se o tipo de modelo é `amazon.nova-2-lite-v1:0:256k`
- Se estiver usando um modelo diferente, mude para um modelo capaz de raciocinar ou remova o parâmetro `reasoning_effort` da sua fórmula

Avaliação de RFT

O que é avaliação de RFT?

A avaliação de RFT permite que você avalie o desempenho do seu modelo usando funções de recompensa personalizadas antes, durante ou após o treinamento de aprendizado por reforço. Ao contrário das avaliações padrão que usam métricas predefinidas, a avaliação de RFT permite que você defina seus próprios critérios de sucesso por meio de uma função do Lambda que pontua os resultados do modelo com base em seus requisitos específicos.

Por que avaliar com o RFT?

A avaliação é crucial para determinar se o processo de ajuste fino do RL:

- Aprimorou o alinhamento de modelos com seu caso de uso específico e valores humanos
- Manteve ou aprimorou os recursos dos modelos nas principais tarefas
- Evitou efeitos colaterais indesejados, como redução da factualidade, aumento da verbosidade ou degradação do desempenho em outras tarefas
- Atendeu aos seus critérios de sucesso personalizados, conforme definido por sua função de recompensa

Quando usar a avaliação de RFT

Use a avaliação de RFT nestes cenários:

- Antes do treinamento de RFT: estabeleça métricas de linha de base em seu conjunto de dados de avaliação
- Durante o treinamento de RFT: monitore o progresso do treinamento com pontos de verificação intermediários
- Após o treinamento de RFT: valide se o modelo final atende aos seus requisitos
- Comparando modelos: avalie várias versões do modelo usando critérios de recompensa consistentes

Note

Use a avaliação de RFT quando precisar de métricas personalizadas e específicas do domínio. Para avaliação de propósito geral (precisão, perplexidade, BLEU), use métodos de avaliação padrão.

Requisitos de formato de dados

Estrutura de dados de entrada

Os dados de entrada da avaliação de RFT devem seguir o formato de ajuste fino por reforço da OpenAI. Cada exemplo é um objeto JSON que contém:

- `messages`: matriz de turnos de conversação com os perfis `system` e `user`
- `reference_answer`: saída esperada ou dados de verdade fundamental usados por sua função de recompensa para pontuação

Exemplo de formato de dados

```
{
  "messages": [
    {
      "role": "user",
      "content": [
```

```

    {
      "type": "text",
      "text": "Solve for x. Return only JSON like {\"x\": <number>}. Equation: 2x +
5 = 13"
    }
  ],
  "reference_answer": {
    "x": 4
  }
}

```

Limitações atuais

- Somente texto: não há compatibilidade com entradas multimodais (imagens, áudio, vídeo)
- Conversas em um único turno: compatível apenas com mensagens de um único usuário (sem diálogos com vários turnos)
- Formato JSON: os dados de entrada devem estar no formato JSONL (um objeto JSON por linha)
- Saídas do modelo: a avaliação é realizada nas conclusões geradas do modelo específico

Preparação da sua fórmula de avaliação

Exemplo de bloco de notas

Para obter um exemplo completo, consulte [Cadernos de avaliação](#).

Configuração do exemplo de fórmula

```

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>

```

Funções de recompensa predefinidas

Duas funções de recompensa predefinidas (`prime_code` e `prime_math`) estão disponíveis como uma camada do Lambda para facilitar a integração com suas funções de RFT do Lambda.

Visão geral

Essas funções predefinidas fornecem recursos de avaliação prontos para uso para:

- `prime_code`: geração de código e avaliação de exatidão
- `prime_math`: raciocínio matemático e avaliação da resolução de problemas

Configuração rápida

1. Faça download da camada do Lambda das [versões nova-custom-eval-sdk](#).
2. Publique a camada do Lambda usando a interface de linha de comandos da AWS (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. Adicione a camada à sua função do Lambda no Console de Gerenciamento da AWS (selecione preset-function-layer da camada personalizada e também adicione AWSSDKPandas-Python312 para dependências numpy).
4. Importe e use no seu código do Lambda:

```
from prime_code import compute_score # For code evaluation
from prime_math import compute_score # For math evaluation
```

função prime_code

Avalia as tarefas de geração de código Python executando o código em casos de teste e avaliando a exatidão.

Exemplo de formato de conjunto de dados de entrada

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

Recursos principais do

- Extração automática de código de blocos de código markdown
- Detecção de funções e testes baseados em chamadas
- Execução de casos de teste com proteção de tempo limite
- Verificações de compilação e validação de sintaxe
- Relatórios detalhados de erros com rastreamentos

prime_math function

Avalia o raciocínio matemático e as capacidades de resolução de problemas com suporte matemático simbólico.

Formato de entrada

```
{"messages":[{"role":"user","content":"What is the derivative of x^2 + 3x?."}], "reference_answer":"2*x + 3"}
```

Recursos principais do

- Avaliação matemática simbólica usando SymPy
- Vários formatos de resposta (LaTeX, texto simples, simbólico)
- Verificação de equivalência matemática
- Simplificação e normalização da expressão

Requisitos de formato de dados

Para avaliação de código

- Entradas: matriz de argumentos de funções (tipos próprios: números inteiros, strings etc.)
- Saídas: matriz de valores de retorno esperados (tipos próprios: booleanos, números etc.)
- Código: deve estar em Python com definições de função claras

Para avaliação matemática

- Resposta de referência: expressão matemática ou valor numérico
- Resposta: pode ser LaTeX, texto simples ou notação simbólica
- Equivalência: verificada simbolicamente, não apenas a correspondência de strings

Práticas recomendadas

- Use tipos de dados adequados em casos de teste (inteiros vs. strings, booleanos vs. "True")
- Forneça assinaturas de funções claras em problemas de código
- Inclua casos de borda nas entradas de teste (zero, números negativos, entradas vazias)
- Formate expressões matemáticas de forma consistente nas respostas de referência
- Teste sua função de recompensa com dados de exemplo antes da implantação

Tratamento de erros

Ambas as funções incluem tratamento robusto de erros para:

- Erros de compilação no código gerado
- Exceções de runtime durante a execução
- Dados de entrada malformados
- Cenários de tempo limite para loops infinitos
- Expressões matemáticas inválidas

Criação da função de recompensa

Requisitos do ARN do Lambda

O ARN do Lambda precisa seguir este formato:

```
"arn:aws:lambda:*:*:function:*SageMaker*"
```

Se o Lambda não tiver esse esquema de nomenclatura, a tarefa falhará com este erro:

```
[ERROR] Unexpected error: lambda_arn must contain one of: ['SageMaker', 'sagemaker', 'Sagemaker'] when running on SMHP platform (Key: lambda_arn)
```

Formato de solicitação do Lambda

Sua função do Lambda recebe dados neste 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

A estrutura da mensagem inclui a matriz content aninhada, correspondente ao formato dos dados de entrada. A última mensagem com o perfil nova_assistant contém a resposta gerada pelo modelo.

Formato de resposta do Lambda

Sua função do Lambda deve retornar dados neste 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"
      }
    ]
  }
]
```

```
    ]
  }
]
```

Campos de resposta

- **id**: deve corresponder ao ID do exemplo de entrada
- **aggregate_reward_score**: pontuação geral (normalmente de 0,0 a 1,0)
- **metrics_list**: matriz de métricas individuais com:
 - **name**: identificador de métricas (por exemplo, “precisão”, “fluência”)
 - **value**: pontuação de métricas (normalmente de 0,0 a 1,0)
 - **type**: “métrica” (para relatórios) ou “recompensa” (usada no treinamento)

permissões do IAM

Permissões obrigatórias

O seu perfil de execução do SageMaker precisa ter as permissões para invocar sua função do Lambda. Adicione esta política ao seu perfil de execução do SageMaker:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "lambda:InvokeFunction"
      ],
      "Resource": "arn:aws:lambda:region:account-id:function:function-name"
    }
  ]
}
```

Função de execução do Lambda

O perfil de execução de uma função do Lambda precisa de permissões básicas de execução do Lambda:

```
{
```

```
"Version": "2012-10-17",
"Statement": [
  {
    "Effect": "Allow",
    "Action": [
      "logs:CreateLogGroup",
      "logs:CreateLogStream",
      "logs:PutLogEvents"
    ],
    "Resource": "arn:aws:logs:*:*:*"
  }
]
```

Se sua função do Lambda acessar outros serviços da AWS (por exemplo, S3 para dados de referência, DynamoDB para registro em log), adicione essas permissões ao perfil de execução do Lambda.

Execução da tarefa de avaliação

1. Preparar seus dados: formate seus dados de avaliação de acordo com os requisitos de formato de dados e carregue seu arquivo JSONL no S3: `s3://your-bucket/eval-data/eval_data.jsonl`
2. Configurar sua fórmula: atualize a fórmula de amostra com sua configuração:
 - Defina `model_name_or_path` para a localização do seu modelo
 - Defina `lambda_arn` para o ARN da função de recompensa
 - Defina `output_s3_path` para o local de saída desejado
 - Ajuste os parâmetros `inference` conforme necessário

Salve a fórmula como `rft_eval_recipe.yaml`

3. Executar a avaliação: execute a tarefa de avaliação usando o caderno fornecido: [Cadernos de avaliação](#)
4. Monitorar o progresso: monitore sua tarefa de avaliação por meio do:
 - Console do SageMaker: verifique o status e os logs da tarefa
 - CloudWatch Logs: visualize logs de execução detalhados
 - Lambda Logs: depure problemas na função de recompensa

Conceitos básicos dos resultados da avaliação

Formato de saída

A tarefa de avaliação gera resultados para a localização específica do S3 no formato JSONL. Cada linha contém os resultados da avaliação de um exemplo:

```
{
  "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

A saída da tarefa de avaliação de RFT é idêntica ao formato da resposta do Lambda. O serviço de avaliação passa pela resposta da função do Lambda sem modificação, garantindo a consistência entre seus cálculos de recompensa e os resultados finais.

Como interpretar os resultados do

Pontuação de recompensa agregada

- Intervalo: normalmente de 0,0 (pior) a 1,0 (melhor), mas depende da sua implementação
- Objetivo: número único resumindo o desempenho geral
- Uso: compare modelos, acompanhe a melhoria em relação ao treinamento

Métricas individuais

- Tipo de métrica: métricas informativas para análise
- Tipo de recompensa: métricas usadas durante o treinamento de RFT
- Interpretação: valores mais altos geralmente indicam melhor desempenho (a menos que você crie métricas inversas)

Benchmarks de desempenho

O que constitui um desempenho “bom” depende do seu caso de uso:

Intervalo de pontuação	Interpretação	Ação
0,8 a 1,0	Excelente	Modelo pronto para implantação
0,6 a 0,8	Boa	Pequenas melhorias podem ser benéficas
0,4 a 0,6	Razoável	Melhoria significativa necessária
0,0 a 0,4	Ruim	Revise os dados de treinamento e a função de recompensa

Important

Essas são as diretrizes gerais. Defina seus próprios limites com base nos requisitos de negócios, no desempenho do modelo de base, nas restrições específicas do domínio e na análise de custo-benefício do treinamento adicional.

Solução de problemas

Problemas comuns

Problema	Causa	Solução
tempo limite do Lambda	Cálculo complexo de recompensas	Aumente o tempo limite do Lambda ou otimize a função

Problema	Causa	Solução
Permissão negada	Ausência de permissões do IAM	Verifique se o perfil do SageMaker pode invocar o Lambda
Pontuações inconsistentes	Função de recompensa não determinística	Use sementes fixas ou lógica determinística
Resultados ausentes	Erros do Lambda não detectados	Adicione tratamento abrangente de erros no Lambda

Lista de verificação de depuração

- Verifique se os dados de entrada seguem o formato correto com matrizes de conteúdo aninhadas
- Confirme se o ARN do Lambda está correto e se a função foi implantada
- Verifique as permissões do IAM para o SageMaker → invocação do Lambda
- Analise os logs do CloudWatch para erros do Lambda
- Valide que a resposta do Lambda corresponde ao formato esperado

Práticas recomendadas

- Começar de forma simples: comece com as funções básicas de recompensa e itere
- Testar o Lambda separadamente: use os eventos de teste do Lambda antes da avaliação completa
- Validar em um conjunto de dados pequeno: execute a avaliação no subconjunto antes do conjunto de dados completo
- Controle da versão: acompanhe as versões da função de recompensa junto com as versões do modelo
- Monitorar os custos: as invocações do Lambda e o tempo de computação afetam os custos
- Registrar em log de forma extensiva: use instruções de impressão no Lambda para depuração
- Definir os tempos limite de forma adequada: concilie tempo de espera e custo
- Métricas do documento: defina claramente o que cada métrica avalia

Próximas etapas

Depois de concluir a avaliação de RFT:

- Se os resultados forem satisfatórios: implante o modelo na produção
- Se for necessário melhorar:
 - Ajuste a função de recompensa
 - Colete mais dados de treinamento
 - Modifique os hiperparâmetros de treinamento
 - Execute iterações adicionais de treinamento de RFT
- Monitoramento contínuo: reavalie periodicamente com novos dados

Implementação de funções de recompensa

Visão geral

A função de recompensa (também chamada de pontuador ou avaliador) é o componente principal que avalia as respostas do modelo e fornece sinais de feedback para o treinamento. Ela deve ser implementada como uma função do Lambda que aceita respostas do modelo e retorna pontuações de recompensa.

Formato da interface

A sua função de recompensa deve aceitar e retornar dados no seguinte formato:

Exemplo de entrada para treinamento

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

Exemplo de carga útil para a recompensa do Lambda

O contêiner transforma automaticamente seus dados antes de enviá-los para sua função do Lambda ao:

1. Gerar uma resposta de modelo para cada prompt
2. Anexar o turno do assistente (resposta gerada) à matriz de mensagens
3. Adicionar um campo de id único de rastreamento

Sua função do Lambda receberá dados neste formato transformado:

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

Contrato de recompensa do 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't 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"
    }
  ]
}
```

"""

Campos de entrada e saída

Campos de entrada

Campo	Descrição	Notas adicionais
id	Identificador único do exemplo	Ecoou de volta na saída. Formato de string
mensagens	Histórico sequencial do chat no formato OpenAI	Matriz de objetos de mensagem
messages[].role	Quem fala a mensagem	Valores comuns: “user”, “assistant”, “system”
messages[].content	O conteúdo do texto da mensagem	String simples
**metadados	Informações de formato livre para auxiliar na classificação	Objeto; campos opcionais dos dados de treinamento

Campos de saída

Campo	Descrição	Notas adicionais
id	Mesmo identificador do exemplo de entrada	Deve corresponder à entrada
aggregate_reward_score	Pontuação geral do exemplo	Flutuante (por exemplo, 0,0 a 1,0, ou intervalo definido pela tarefa)
metrics_list	Pontuações de componentes que compõem o agregado	Matriz de objetos de métricas

Restrições técnicas

- Limite de tempo: 15 minutos de tempo máximo de execução por invocação do Lambda
- Simultaneidade: deve lidar com solicitações `rollout_worker_replicas * 64` simultâneas

- **Confiabilidade:** deve implementar o tratamento adequado de erros e retornar pontuações válidas de forma consistente
- **Desempenho:** otimiza para uma execução rápida (segundos, não minutos) para permitir um treinamento eficiente

Práticas recomendadas

- Minimize as chamadas de API externas
- Use algoritmos e estruturas de dados eficientes
- Implementar a lógica de novas tentativas para falhas transitórias
- Armazenar em cache cálculos reutilizáveis
- Testar minuciosamente antes do treinamento para garantir uma execução sem erros

Uso de funções de recompensa personalizadas

Implemente funções de recompensa personalizadas quando você tiver critérios de avaliação específicos da tarefa:

- **Definir critérios de avaliação:** determine o que constitui uma boa resposta para sua tarefa
- **Implementar a função do Lambda:** crie uma função do Lambda seguindo o formato da interface
- **Testar localmente:** valide se sua função retorna as pontuações corretas para as entradas do exemplo
- **Implantar na AWS:** implante seu Lambda e anote o ARN
- **Configurar fórmula:** adicione o ARN do Lambda ao campo `reward_lambda_arn` da sua fórmula
- **Testar com um pequeno conjunto de dados:** execute o RFT com o mínimo de dados para verificar a integração

permissões do IAM

Permissões obrigatórias

O seu perfil de execução do SageMaker precisa ter as permissões para invocar sua função do Lambda. Adicione esta política ao seu perfil de execução do SageMaker:

```
{  
  "Version": "2012-10-17",
```

```
"Statement": [  
  {  
    "Effect": "Allow",  
    "Action": [  
      "lambda:InvokeFunction"  
    ],  
    "Resource": "arn:aws:lambda:region:account-id:function:function-name"  
  }  
]  
}
```

Função de execução do Lambda

O perfil de execução de uma função do Lambda precisa de permissões básicas de execução do Lambda:

```
{  
  "Version": "2012-10-17",  
  "Statement": [  
    {  
      "Effect": "Allow",  
      "Action": [  
        "logs:CreateLogGroup",  
        "logs:CreateLogStream",  
        "logs:PutLogEvents"  
      ],  
      "Resource": "arn:aws:logs:*:*:*"  
    }  
  ]  
}
```

Permissões adicionais: se a função do Lambda acessar outros serviços da AWS (por exemplo, S3 para dados de referência, DynamoDB para registro em log), adicione essas permissões ao perfil de execução do Lambda.

Exemplo: função de recompensa para LLM como avaliador

Este exemplo demonstra o uso de modelos do Amazon Bedrock como avaliadores para analisar as respostas do modelo comparando-as com as respostas de referência. Esse modelo do Lambda fornece um framework para os clientes implementarem chamadas no Amazon Bedrock de solicitações de inferência para processar as análises dos avaliadores. A função do Lambda mantém o mesmo contrato de entrada/saída que outras funções de recompensa.

Implementação

Essa função do Lambda implementa um processo de avaliação em duas etapas: o `lambda_handler` extrai as respostas do modelo e as respostas de referência das amostras recebidas e, em seguida, a função `lambda_graded` chama o Amazon Bedrock para pontuar a semelhança semântica entre elas. A implementação inclui tratamento robusto de erros com novas tentativas automáticas para falhas transitórias e é compatível com formatos flexíveis de resposta de referência (formatos de string e dicionário estruturado).

Detalhes da implantação:

- Repetir a lógica: implementa o recuo exponencial (1s, 2s, 4s) para controlar a utilização de exceções para lidar com os limites de taxa da API do Bedrock
- Tratamento de erros: retorna a pontuação de 0,0 para avaliações com falha, em vez de gerar exceções
- Pontuação determinística: usa `temperature = 0,0` para garantir pontuações consistentes em todas as avaliações
- Formato de referência flexível: processa automaticamente as respostas de referência de texto e dicionário
- Limitadores de pontuação: garante que todas as pontuações estejam no intervalo válido [0,0, 1,0]
- Modelo agnóstico: altera `JUDGE_MODEL_ID` para usar qualquer modelo do Amazon Bedrock (Nova, Llama, Mistral etc.)

```
"""
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 de entrada

O Lambda recebe o mesmo formato de entrada que outras funções de recompensa:

```

{
  "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 de saída

```

{
  "id": "sample-001",
  "aggregate_reward_score": 0.85,
  "metrics_list": [
    {

```

```
        "name": "similarity_score",
        "value": 0.85,
        "type": "Metric"
    }
]
```

Considerações de implantação

Talvez você também precise ajustar o modelo do prompt e os parâmetros de inferência com base nos recursos do modelo escolhido e no formato da API.

- Permissões do IAM: o perfil de execução do Lambda deve ter a permissão `bedrock:InvokeModel` para o modelo escolhido
- Tempo limite: defina o tempo limite do Lambda para pelo menos 60 segundos para acomodar a latência e as novas tentativas da API do Bedrock
- Região: implante em uma região onde o modelo escolhido do Bedrock esteja disponível
- Custo: monitore o uso da API do Bedrock à medida que cada avaliação faz uma chamada de API por exemplo
- Throughput: para avaliações em grande escala, solicite maiores cotas do Bedrock para evitar o controle de utilização

Aumento do throughput do Bedrock

Se você observar controle de utilização durante a avaliação, aumente suas cotas do modelo Bedrock:

- Navegue até o console do AWS Service Quotas
- Pesquise por “Bedrock” e selecione sua região
- Encontre a cota para o modelo escolhido (por exemplo, “Invocações por minuto para o Claude 3.5 Sonnet”)
- Clique em “Solicitar aumento de cota” e especifique o throughput desejado
- Forneça uma justificativa para o aumento (por exemplo, “workload de avaliação de RFT”)

A lógica de repetição integrada do Lambda lida com o controle de utilização ocasional, mas as avaliações sustentadas de alto volume exigem aumentos de cota apropriados.

Política do IAM necessária:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "bedrock:InvokeModel"
      ],
      "Resource": "arn:aws:bedrock:*::foundation-model/*"
    }
  ]
}
```

Treinamento iterativo

O treinamento iterativo é uma abordagem sistemática para ajustar modelos por meio de vários ciclos de treinamento, em que cada rodada se baseia no ponto de verificação anterior, abordando pontos fracos específicos descobertos por meio da avaliação. Esse método permite melhorias direcionadas na performance do modelo, incorporando exemplos selecionados que abordam os modos de falha, adaptando-se às mudanças nos requisitos e validando os aprimoramentos de forma incremental, em vez de se comprometer com uma única execução de treinamento longo. O processo normalmente segue padrões como o SFT (ajuste fino supervisionado) seguido pelo RFT (ajuste fino baseado em recompensa), com pontos de verificação armazenados em buckets de depósito do S3 gerenciados pela AWS que podem ser referenciados para iterações de treinamento subsequentes, mantendo a consistência no tipo de modelo e na técnica de treinamento em todo o pipeline.

Para obter mais detalhes, consulte [???](#).

Personalização do Amazon Nova no SageMaker HyperPod

Você pode personalizar os modelos do Amazon Nova, incluindo os modelos aprimorados do Amazon Nova 2.0, usando as [fórmulas do Amazon Nova](#) e treinando-os no Hyperpod. Uma receita é um arquivo de configuração YAML que fornece ao SageMaker AI detalhes sobre como executar a tarefa de personalização de modelo. O SageMaker HyperPod é compatível com dois tipos de serviços: Forge e Não Forge.

O HyperPod oferece computação de alta performance com instâncias de GPU otimizadas e armazenamento do Amazon FSx para Lustre, monitoramento avançado por meio da integração

com ferramentas como o TensorBoard, gerenciamento flexível de pontos de verificação para aprimoramento iterativo, implantação sem falhas no Amazon Bedrock para inferência e treinamento distribuído de vários nós eficiente e escalável, tudo trabalhando em conjunto para fornecer às organizações um ambiente de alta performance seguro e flexível para personalizar os modelos do Amazon Nova de acordo com os requisitos de cada uma.

A personalização do Amazon Nova no SageMaker HyperPod armazena artefatos de modelo, incluindo pontos de verificação de modelos, em um bucket do Amazon S3 gerenciado pelo serviço. Os artefatos no bucket gerenciado pelo serviço são criptografados com chaves do AWS KMS gerenciadas pelo SageMaker AI. No momento, os buckets do Amazon S3 gerenciados pelo serviço não são compatíveis com criptografia de dados usando chaves do KMS gerenciadas pelo cliente. Você pode usar esse ponto de verificação para tarefas de avaliação ou para inferência do Amazon Bedrock.

O preço padrão pode ser aplicado a instâncias de computação, ao armazenamento do Amazon S3 e ao FSx para Lustre. Para obter detalhes de preços, consulte [Preços do HyperPod](#), [Preços do Amazon S3](#) e [Preços do FSx para Lustre](#).

Requisitos de computação para os modelos do Amazon Nova 2

As tabelas a seguir resumem os requisitos de computação e o treinamento de tarefas de treinamento do SageMaker AI e do HyperPod para modelos do Amazon Nova 2.

Requisitos de treinamento do Nova 2

Técnica de treinamento	Instâncias mínimas	Tipo de instância	Contagem de GPU	Observações	Modelos compatíveis
SFT (LoRA)	4	P5.48xlarge	16	Ajuste fino com eficiência de parâmetros	Nova 2 Lite
SFT (full-rank)	4	P5.48xlarge	32	Ajuste fino completo de modelos	Nova 2 Lite
RFT nas tarefas de	2	P5.48xlarge	16	Funções de recompens	Nova 2 Lite

Técnica de treinamento	Instâncias mínimas	Tipo de instância	Contagem de GPU	Observações	Modelos compatíveis
treinamen to do SageMaker (LoRA)				a personali zadas em seu ambiente da AWS	
RFT sobre tarefas de treinamen to do SageMaker (full-rank)	4	P5.48xlarge	32	Extensão de contexto de 32 mil	Nova 2 Lite
RFT no SageMaker HyperPod	8	P5.48xlarge	64	Extensão de contexto padrão de 8.192	Nova 2 Lite
CPT	4	P5.48xlarge	16	Processa aproximad amente 400 milhões de tokens por instância por dia	Nova 2 Lite

Para otimizar seus fluxos de trabalho de personalização de modelos do Amazon Nova no Hyperpod, siga estas práticas recomendadas para treinamento eficiente, gerenciamento de recursos e implantação bem-sucedida de modelos.

Práticas recomendadas para personalização do Amazon Nova

Visão geral

Esta seção fornece uma visão geral das técnicas de personalização e ajuda você a escolher a melhor abordagem para suas necessidades e dados disponíveis.

Duas etapas do treinamento de LLM

O treinamento de grandes modelos de linguagem consiste em duas etapas principais: pré-treinamento e pós-treinamento. Durante o pré-treinamento, o modelo processa tokens de texto bruto e otimiza a predição do próximo token. Esse processo cria um completador de padrões que absorve a sintaxe, a semântica, os fatos e os padrões de raciocínio da web e do texto selecionado. No entanto, o modelo pré-treinado não compreende as instruções, as metas do usuário ou o comportamento adequado ao contexto. Ele continua o texto em qualquer estilo adequado à sua distribuição de treinamento. Um modelo pré-treinado é preenchido automaticamente em vez de seguir as instruções, produz formatação inconsistente e pode refletir vieses indesejáveis ou conteúdo inseguro provenientes dos dados de treinamento. O pré-treinamento desenvolve a competência geral, não a utilidade da tarefa.

O pós-treinamento transforma o completador de padrões em um assistente útil. Você executa várias rodadas de ajuste fino supervisionado (SFT) para ensinar o modelo a seguir instruções, a aderir a esquemas e políticas, a chamar ferramentas e a gerar resultados confiáveis imitando demonstrações de alta qualidade. Esse alinhamento ensina o modelo a responder aos prompts como tarefas, em vez de texto para continuar. Em seguida, você aplica o ajuste fino por reforço (RFT) para otimizar o comportamento usando feedback mensurável (como verificadores ou um LLM como avaliador), equilibrando compensações como precisão versus brevidade, segurança versus cobertura ou raciocínio em várias etapas sob restrições. Na prática, você alterna o SFT e o RFT em ciclos para transformar o modelo pré-treinado em um sistema confiável e alinhado a políticas que executa tarefas complexas de forma consistente.

Escolher a abordagem certa de personalização

Nesta seção, abordaremos as estratégias de personalização pós-treinamento: RFT e SFT.

Ajuste fino por reforço (RFT)

O ajuste fino por reforço melhora o desempenho do modelo por meio de sinais de feedback (pontuações mensuráveis ou recompensas que indicam a qualidade da resposta) em vez de supervisão direta com respostas exatas e corretas. Ao contrário do ajuste fino supervisionado tradicional que aprende com pares de entrada e saída, o RFT usa funções de recompensa para avaliar as respostas do modelo e otimiza iterativamente o modelo para maximizar essas recompensas. Essa abordagem funciona bem para tarefas em que definir a saída correta exata é um desafio, mas você pode avaliar com segurança a qualidade da resposta. O RFT permite que os modelos aprendam comportamentos e preferências complexos por meio de testes e feedback,

tornando-o ideal para aplicações que exigem uma tomada de decisão diferenciada, uma solução criativa de problemas ou uma adesão a critérios de qualidade específicos que você pode avaliar de forma programática. Por exemplo, responder a questões jurídicas complexas é um caso de uso ideal para o RFT porque você quer ensinar ao modelo como raciocinar melhor para responder a perguntas com mais precisão.

Como funciona

No ajuste fino por reforço, você parte de uma linha de base ajustada às instruções e trata cada prompt como um pequeno torneio. Para uma determinada entrada, você coleta amostras de algumas respostas candidatas do modelo, pontua cada uma com a função de recompensa e as classifica dentro desse grupo. A etapa de atualização aprimora o modelo para tornar os candidatos com a pontuação mais alta os mais prováveis na próxima vez, e os com pontuação mais baixa os menos prováveis, enquanto uma restrição de proximidade à linha de base evita o desvio de comportamento, a verbosidade ou o tom exploratório. Você repete esse ciclo em vários prompts, atualizando casos difíceis, reforçando os verificadores ou avaliando rubricas quando vê um tom exploratório e rastreando continuamente as métricas das tarefas.

Quando usar o RFT

As tarefas que mais se beneficiam do RFT compartilham várias características. Elas têm sinais de sucesso mensuráveis, mesmo quando é difícil especificar uma única saída correta. Elas admitem pontuação parcial ou qualidade escalonada para que você possa classificar as melhores e piores respostas em um prompt ou usando uma função de recompensa. Elas envolvem vários objetivos que devem ser equilibrados (como precisão com brevidade, clareza, segurança ou custo). Elas exigem a adesão a restrições explícitas que podem ser verificadas de forma programática. Elas operam em ambientes mediados por ferramentas ou baseados no ambiente, em que os resultados são observáveis (sucesso ou falha, latência, uso de recursos). Elas ocorrem em regimes de poucos rótulos, em que a coleta de alvos de referência é dispendiosa, mas o feedback automatizado ou baseado em rubricas é abundante. O RFT funciona melhor quando você pode transformar a qualidade em um escalar ou uma classificação confiável e deseja que o modelo amplifique preferencialmente os comportamentos de maior pontuação sem precisar de metas rotuladas exaustivas.

Considere outros métodos quando:

- Você tem pares de entrada-saída rotulados, abundantes e confiáveis: use o SFT
- A principal lacuna é o conhecimento ou o jargão: use a geração aumentada via recuperação (RAG)

- O sinal de recompensa apresenta ruído ou falta de confiabilidade, sem possibilidade de correção via rubricas ou verificadores: estabilize esse ponto antes de prosseguir com o RFT

Quando não usar o RFT

Evite o RFT nestas situações:

- Você pode produzir de forma barata pares de entrada-saída rotulados confiáveis (o SFT é mais simples, barato e mais estável)
- A lacuna é conhecimento ou jargão, em vez de comportamento (use a RAG)
- Seu sinal de recompensa apresenta ruído, é esparso, fácil de burlar ou tem computação cara ou lenta (corrija o avaliador primeiro)
- O desempenho da linha de base é próximo de zero (inicialize com o SFT antes de otimizar as preferências)
- A tarefa tem esquemas determinísticos, formatação estrita ou uma única resposta correta (SFT ou validação baseada em regras funciona melhor)
- Limitações rígidas de latência ou orçamento não suportam a amostragem ou exploração extra exigida pelo RFT
- As restrições de segurança ou políticas não são especificadas de forma precisa e aplicáveis na recompensa

Se você puder apontar para “a resposta certa”, use o SFT. Se você precisar de novos conhecimentos, use a RAG. Use o RFT somente depois de ter uma linha de base sólida e uma função de recompensa robusta, rápida e difícil de explorar.

Ajuste fino supervisionado (SFT)

O ajuste fino supervisionado treina o LLM em um conjunto de dados de pares de entrada-saída rotulados por humanos para sua tarefa. Você fornece exemplos de prompts (perguntas, instruções etc.) junto com as respostas corretas ou desejadas e continua treinando o modelo com base nelas. O modelo ajusta o peso para minimizar uma perda supervisionada (normalmente entropia cruzada entre suas previsões e os tokens de saída esperados). Esse é o mesmo treinamento usado na maioria das tarefas supervisionadas de machine learning, aplicado para especializar um LLM.

O SFT muda o comportamento, não o conhecimento. Ele não ensina ao modelo novos fatos ou jargões que não foram vistos no pré-treinamento. Ela ensina ao modelo como responder, não o que saber. Se você precisar de um novo conhecimento de domínio (como terminologia interna), use a

geração aumentada via recuperação (RAG) para fornecer esse contexto no momento da inferência. Posteriormente, o SFT incorpora o comportamento de seguimento de instruções desejado à estrutura do modelo.

Como funciona

O SFT otimiza o LLM minimizando a perda média de entropia cruzada nos tokens de resposta, tratando os tokens de prompts como contexto e mascarando-os da perda. O modelo internaliza seu estilo alvo, estrutura e regras de decisão, aprendendo a gerar a finalização correta para cada prompt. Por exemplo, para classificar documentos em categorias personalizadas, você ajusta o modelo com prompts (o texto do documento) e conclusões rotuladas (os rótulos das categorias). Você treina nesses pares até que o modelo gere o rótulo correto para cada prompt com alta probabilidade.

Você pode executar o SFT com apenas algumas centenas de exemplos e aumentar a escala verticalmente até algumas centenas de milhares. As amostras do SFT devem ser de alta qualidade e estar diretamente alinhadas com o comportamento desejado do modelo.

Quando usar o SFT

O SFT é melhor quando você tem uma tarefa bem definida com as saídas desejadas claras. Se você puder declarar explicitamente “Dada a entrada X, a saída correta/desejada é Y” e reunir exemplos desses mapeamentos, o ajuste fino supervisionado será uma ótima opção. O SFT se destaca nestes cenários:

- Tarefas de classificação estruturadas ou complexas: classificar documentos ou contratos internos em várias categorias personalizadas. Com o SFT, o modelo aprende essas categorias específicas muito melhor do que apenas gerando prompts.
- Tarefas de questionamento e resposta ou transformação com respostas conhecidas: ajustar um modelo para responder a perguntas da base de conhecimentos de uma empresa ou converter dados entre formatos, em que cada entrada tem uma resposta correta.
- Formatação e consistência de estilo: treine o modelo para que sempre responda em um determinado formato ou tom, ajustando exemplos do formato ou tom correto. Por exemplo, o treinamento em pares de prompt-resposta que demonstram uma voz de marca específica ensina o modelo a gerar saídas com esse estilo. O comportamento de seguir as instruções geralmente é ensinado logo no início via SFT em exemplos selecionados de bom comportamento do assistente.

O SFT é a maneira mais direta de ensinar a um LLM uma nova habilidade ou comportamento quando você pode especificar qual é o comportamento correto. Ele aproveita a compreensão da

linguagem existente do modelo e a concentra em sua tarefa. Use o SFT quando quiser que o modelo faça algo específico e você tiver ou puder criar um conjunto de dados de exemplos.

Use o SFT quando puder montar pares de prompts e respostas de alta qualidade que reflitam com precisão o comportamento desejado. Ele se adapta a tarefas com metas claras ou formatos determinísticos, como esquemas, chamadas de funções ou ferramentas e respostas estruturadas, em que a imitação é um sinal de treinamento apropriado. O objetivo é moldar o comportamento: ensinar o modelo a tratar prompts como tarefas, seguir instruções, adotar políticas de tom e recusa e produzir uma formatação consistente. Planeje pelo menos centenas de demonstrações, com a qualidade, a consistência e a deduplicação de dados sendo mais importante do que o volume bruto. Para uma atualização direta e econômica, use métodos eficientes em termos de parâmetros, como o Low-Rank Adaptation, para treinar adaptadores pequenos e, ao mesmo tempo, deixar a maior parte da estrutura intocada.

Quando não usar o SFT

Não use o SFT quando a lacuna for conhecimento e não comportamento. Ele não ensina ao modelo novos fatos, jargões ou eventos recentes. Nesses casos, use a geração aumentada via recuperação para trazer conhecimento externo para inferência. Evite o SFT quando você pode avaliar a qualidade, mas não consegue rotular uma única resposta certa. Use o ajuste fino por reforço com recompensas verificáveis ou um LLM como avaliador para otimizar essas recompensas diretamente. Se suas necessidades ou conteúdo mudarem com frequência, priorize a recuperação e o uso de ferramentas em vez de treinar novamente o modelo.

Tópicos

- [Nova Forge SDK](#)
- [Criação de um cluster do EKS no HyperPod com um grupo de instâncias restritas \(RIG\)](#)
- [Guia de comandos essenciais do Amazon SageMaker HyperPod](#)
- [Configuração e acesso ao Nova Forge para](#)
- [Treinamento para modelos do Amazon Nova](#)
- [Avaliar o modelo treinado](#)
- [Monitoramento das tarefas do HyperPod com o MLflow](#)

Nova Forge SDK

O Amazon Nova Forge SDK é um SDK abrangente para Python que fornece uma interface programática unificada para o ciclo de vida completo da personalização de modelos do Amazon

Nova. O SDK simplifica a personalização de modelos ao oferecer uma API única e consistente para treinamento, avaliação, monitoramento, implantação e inferência nas plataformas do Amazon SageMaker e Amazon Bedrock.

Para obter mais informações, consulte [Nova Forge SDK](#).

Criação de um cluster do EKS no HyperPod com um grupo de instâncias restritas (RIG)

Para personalizar um modelo no Hyperpod, a infraestrutura necessária deve ser configurada. Para obter detalhes sobre como configurar um cluster do EKS no SageMaker HyperPod com um grupo de instâncias restritas (RIG), acesse o [workshop](#), que apresenta um guia detalhado do processo de configuração.

Guia de comandos essenciais do Amazon SageMaker HyperPod

O Amazon SageMaker HyperPod fornece uma ampla funcionalidade de linha de comando para gerenciar fluxos de trabalho de treinamento. Este guia aborda os comandos essenciais para operações comuns, desde a conexão com seu cluster até o monitoramento do progresso da tarefa.

Pré-requisitos

Antes de usar esses comandos, conclua a seguinte configuração:

- Cluster do SageMaker HyperPod com o RIG criado (normalmente em us-east-1)
- Saída do bucket do Amazon S3 criado para artefatos de treinamento
- Perfis do IAM configurados com as permissões apropriadas
- Dados de treinamento enviados no formato JSONL correto
- Sincronização do FSx para Lustre concluída (verifique nos logs do cluster no primeiro trabalho)

Tópicos

- [Instalação da CLI para fórmulas](#)
- [Conectar-se a um cluster](#)
- [Início de uma tarefa de treinamento](#)
- [Monitoramento do status da tarefa](#)
- [Monitoramento dos logs de tarefas](#)
- [Listagem das tarefas ativas](#)

- [Cancelar uma tarefa](#)
- [Execução de uma tarefa de avaliação](#)
- [Problemas comuns](#)

Instalação da CLI para fórmulas

Navegue até a raiz do repositório de fórmulas antes de executar o comando de instalação.

Use o repositório Hyperpodrecipes se estiver usando técnicas de personalização que não sejam do Forge. Para personalização baseada no Forge, consulte o repositório de fórmulas específico do Forge.

Execute os seguintes comandos para instalar a CLI do SageMaker HyperPod:

Note

Verifique se você não está em um ambiente conda/anaconda/miniconda ativo ou em outro ambiente virtual

Se estiver, saia do ambiente usando:

- `conda deactivate` para ambientes conda/anaconda/miniconda
- `deactivate` para ambientes virtuais Python

Se você estiver usando uma técnica de personalização que não seja do Forge, faça o download de `sagemaker-hyperpod-recipes`, conforme mostrado abaixo:

```
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 você é assinante do Forge, deve fazer o download das fórmulas usando o processo mencionado abaixo.

```
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

Para usar um [novo ambiente virtual](#) antes de executar `pip install -e .`, execute:

- `python -m venv nova_forge`
- `source nova_forge/bin/activate`
- Sua linha de comando agora será exibida (`nova_forge`) no início do seu prompt
- Isso garante que não haja dependências concorrentes ao usar a CLI

Objetivo: por que executamos `pip install -e .`?

Esse comando instala a CLI do SageMaker HyperPod no modo editável, permitindo que você use fórmulas atualizadas sem precisar reinstalá-las todas as vezes. Ele também permite que você adicione novas fórmulas que a CLI pode coletar automaticamente.

Conectar-se a um cluster

Conecte a CLI do SageMaker HyperPod ao seu cluster antes de executar qualquer tarefa:

```
export AWS_REGION=us-east-1 && SageMaker HyperPod connect-cluster --cluster-name
<your-cluster-name> --region us-east-1
```

 Important

Esse comando cria um arquivo de contexto (/tmp/hyperpod_context.json) que os comandos subsequentes exigem. Se você vir um erro informando que esse arquivo não foi encontrado, execute novamente o comando connect.

Dica profissional: você pode configurar ainda mais seu cluster para sempre usar o namespace kubeflow adicionando o argumento `--namespace kubeflow` ao seu comando da seguinte forma:

```
export AWS_REGION=us-east-1 && \  
hyperpod connect-cluster \  
--cluster-name <your-cluster-name> \  
--region us-east-1 \  
--namespace kubeflow
```

Isso elimina a necessidade de adicionar o `-n kubeflow` em cada comando ao interagir com suas tarefas.

Início de uma tarefa de treinamento

 Note

Se estiver executando tarefas de PPO/RFT, certifique-se de adicionar as configurações do seletor de rótulos a `src/hyperpod_cli/sagemaker_hyperpod_recipes/recipes_collection/cluster/k8s.yaml` para que todos os pods sejam programados no mesmo nó.

```
label_selector:  
  required:  
    sagemaker.amazonaws.com/instance-group-name:  
      - <rig_group>
```

Inicie uma tarefa de treinamento usando uma fórmula com substituições de parâmetros opcionais:

```
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"
}'
```

Saída esperada:

```
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>"
}
```

Monitoramento do status da tarefa

Monitore suas tarefas em execução usando o kubectl:

```
kubectl get pods -o wide -w -n kubeflow | (head -n1 ; grep <your-job-name>)
```

Noções básicas sobre os status de pods

A tabela abaixo explica os status comuns de pods:

Status	Descrição
Pending	O pod foi aceito, mas ainda não foi programado para um nó, ou está aguardando a extração das imagens do contêiner
Running	Pod vinculado a um nó com pelo menos um contêiner em execução ou iniciando
Succeeded	Todos os contêineres foram concluídos com sucesso e não serão reiniciados
Failed	Todos os contêineres foram encerrados, com pelo menos um apresentando falha
Unknown	O estado do pod não pode ser determinado (geralmente devido a problemas de comunicação dos nós)
CrashLoopBackOff	O contêiner falha repetidamente; o Kubernetes está suspendendo novas tentativas de reinicialização
ImagePullBackOff / ErrImagePull	Não é possível extrair a imagem do contêiner do registro
OOMKilled	Contêiner encerrado por exceder os limites de memória
Completed	Tarefa ou pod concluído com êxito (conclusão das tarefas em lote)

 Tip

Use o sinalizador `-w` para acompanhar as atualizações de status dos pods em tempo real. Pressione `Ctrl+C` para parar de acompanhar.

Monitoramento dos logs de tarefas

Você pode visualizar seus logs de três maneiras:

Usar o CloudWatch

Seus logs estão disponíveis em sua conta da AWS que contém o Hyperpodcluster no CloudWatch. Para visualizá-los em seu navegador, navegue até a página inicial do CloudWatch em sua conta e pesquise o nome do seu cluster. Por exemplo, se seu cluster se chamasse `my-hyperpod-rig`, o grupo de logs teria o prefixo:

- Grupo de logs: `/aws/sagemaker/Clusters/my-hyperpod-rig/{UUID}`
- Quando estiver no grupo de logs, você poderá encontrar seu log específico usando o ID da instância do nó, como `hyperpod-i-00b3d8a1bf25714e4`.
 - `i-00b3d8a1bf25714e4` aqui representa o nome da máquina compatível com Hyperpod em que sua tarefa de treinamento está sendo executada. Lembre-se de como, na saída anterior do comando `kubectl get pods -o wide -w -n kubeflow | (head -n1 ; grep my-cpt-run)`, capturamos uma coluna chamada `NODE`.
- Nesse caso, a execução do nó “principal” estava sendo realizada em `hyperpod-i-00b3d8a1bf25714e4` e, portanto, usaremos essa string para selecionar o grupo de logs a ser visualizado. Selecione a que diz `SagemakerHyperPodTrainingJob/rig-group/[NODE]`

Uso do CloudWatch Insights

Se você souber o nome da sua tarefa e não quiser seguir todas as etapas acima, basta consultar todos os logs em `/aws/sagemaker/Clusters/my-hyperpod-rig/{UUID}` para encontrar o log individual.

CPT:

```
fields @timestamp, @message, @logStream, @log
| filter @message like /(?(i)Starting CPT Job/
| sort @timestamp desc
| limit 100
```

Para concluir a tarefa, substitua `Starting CPT Job` por `CPT Job completed`

Em seguida, você pode clicar nos resultados e escolher aquele que diz “Epoch 0”, pois este será seu nó principal.

Como usar o AWS CLI AWS

Você pode optar por monitorar seus logs usando a AWS CLI. Antes de fazer isso, verifique sua versão da AWS CLI usando `aws --version`. Também é recomendável usar esse script utilitário que ajuda no rastreamento de logs em tempo real em seu terminal.

para V1:

```
aws logs get-log-events \
--log-group-name /aws/sagemaker/YourLogGroupName \
--log-stream-name YourLogStream \
--start-from-head | jq -r '.events[].message'
```

para V2:

```
aws logs tail /aws/sagemaker/YourLogGroupName \
--log-stream-name YourLogStream \
--since 10m \
--follow
```

Listagem das tarefas ativas

Veja todas as tarefas em execução no seu cluster:

```
hyperpod list-jobs -n kubeflow
```

Resultado do exemplo:

```
{
  "jobs": [
    {
      "Name": "test-run-nhgza",
      "Namespace": "kubeflow",
      "CreationTime": "2025-10-29T16:50:57Z",
      "State": "Running"
    }
  ]
}
```

```
}
```

Cancelar uma tarefa

Interrompa uma tarefa em execução a qualquer momento:

```
hyperpod cancel-job --job-name <job-name> -n kubeflow
```

Localização do nome da sua tarefa

Opção 1: da sua fórmula

O nome da tarefa é especificado no bloco `run` da sua fórmula:

```
run:
  name: "my-test-run"                # This is your job name
  model_type: "amazon.nova-micro-v1:0:128k"
  ...
```

Opção 2: do comando `list-jobs`

Use `hyperpod list-jobs -n kubeflow` e copie o campo `Name` da saída.

Execução de uma tarefa de avaliação

Avalie um modelo treinado ou modelo de base usando uma fórmula de avaliação.

Pré-requisitos

Antes de executar tarefas de avaliação, verifique se você tem:

- O URI do ponto de verificação do Amazon S3 do arquivo `manifest.json` da tarefa de treinamento (para modelos treinados)
- O conjunto de dados de avaliação carregado para o Amazon S3 no formato correto
- O caminho da saída do Amazon S3 para obter os resultados da avaliação

Command

Execute o seguinte comando para iniciar uma tarefa de avaliação:

```
hyperpod start-job -n kubeflow \
  --recipe evaluation/nova/nova_2_0/nova_lite/
nova_lite_2_0_p5_48xl_gpu_bring_your_own_dataset_eval \
  --override-parameters '{
    "instance_type": "p5.48xlarge",
    "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-
HP-Eval-latest",
    "recipes.run.name": "<your-eval-job-name>",
    "recipes.run.model_name_or_path": "<checkpoint-s3-uri>",
    "recipes.run.output_s3_path": "s3://<your-bucket>/eval-results/",
    "recipes.run.data_s3_path": "s3://<your-bucket>/eval-data.jsonl"
  }'
```

Descrições dos parâmetros:

- `recipes.run.name`: o nome exclusivo para sua tarefa de avaliação
- `recipes.run.model_name_or_path`: o URI do Amazon S3 de `manifest.json` ou o caminho do modelo base (p. ex., `nova-micro/prod`)
- `recipes.run.output_s3_path`: o local do Amazon S3 para obter os resultados da avaliação
- `recipes.run.data_s3_path`: o local do seu conjunto de dados de avaliação no Amazon S3

Dicas:

- Fórmulas específicas de modelos: cada tamanho de modelo (micro, lite, pro) tem sua própria fórmula de avaliação
- Avaliação de modelos de base: use caminhos de modelos de base (p. ex., `nova-micro/prod`) em vez de URIs de ponto de verificação para avaliar modelos de base

Formato dos dados de avaliação

Formato de entrada (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 de saída:

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

Descrições dos campos:

- **prompt:** entrada formatada enviada ao modelo
- **inference:** resposta gerada do modelo
- **gold:** resposta correta esperada do conjunto de dados de entrada
- **metadata:** metadados opcionais transmitidos da entrada

Problemas comuns

- **ModuleNotFoundError:** No module named 'nemo_launcher', talvez seja necessário adicionar `nemo_launcher` ao seu caminho Python com base em onde `hyperpod_cli` está instalado. Exemplo de comando:

```
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 que você não executou o comando `hyperpod connect cluster`.
- Caso sua tarefa não apareça como agendada, verifique se a saída da CLI do SageMaker HyperPod tem essa seção com os nomes de tarefas e outros metadados. Caso contrário, reinstale o chart do Helm executando:

```
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
```

Configuração e acesso ao Nova Forge para

Para configurar o Amazon Nova Forge para ser usado com as tarefas, você precisa:

- Inscrever-se no Amazon Nova Forge
- Configurar um cluster

Tópicos

- [Inscrever-se no Amazon Nova Forge](#)
- [Configurar a infraestrutura](#)
- [IA responsável](#)

Inscrever-se no Amazon Nova Forge

Para acessar os recursos do Amazon Nova Forge, conclua as seguintes etapas:

1. Verifique o acesso do administrador à conta da AWS.
2. Navegue até o console do SageMaker AI e [solicite acesso ao Amazon Nova Forge](#).
3. Aguarde até que a equipe do Amazon Nova envie um e-mail de confirmação após a aprovação da solicitação da inscrição.
4. Marque seu perfil de execução com a tag `forge-subscription`. Essa tag é necessária para acessar os recursos e pontos de verificação do Amazon Nova Forge. Adicione a seguinte tag ao seu perfil de execução:
 - Chave: `forge-subscription`
 - Valor: `true`

Note

Os recursos padrão do Amazon Nova permanecem disponíveis sem uma inscrição do Forge. O Amazon Nova Forge foi projetado para criar modelos de fronteira personalizados com controle e flexibilidade em todas as fases de treinamento de modelos.

Configurar a infraestrutura

Depois que sua inscrição do Amazon Nova Forge for aprovada, configure a infraestrutura necessária para usar os recursos habilitados para o Forge. Para obter instruções detalhadas sobre como criar um cluster do EKS com um grupo de instâncias restritas (RIG), siga as [instruções do workshop](#).

IA responsável

Configurações de moderação de conteúdo: os clientes do Amazon Nova Forge têm acesso às configurações de moderação de conteúdo personalizáveis (CCMS) para os modelos do Amazon Nova Lite 1.0 e Pro 1.0. O CCMS permite que você ajuste os controles de moderação de conteúdo para se alinhar aos seus requisitos empresariais específicos, mantendo as proteções essenciais de IA responsável. Para determinar se seu caso de uso empresarial se qualifica para o CCMS, entre em contato com seu gerente de conta da Amazon Web Services.

O Amazon Nova Forge fornece um kit de ferramentas de IA responsável que inclui dados de treinamento, avaliações comparativas e controles de runtime para ajudar você a alinhar seus modelos às diretrizes de IA responsável do Amazon Nova.

Dados de treinamento: a categoria “RAI” na combinação de dados contém casos e cenários que enfatizam os princípios de IA responsável, as considerações de segurança e a implantação responsável de tecnologia. Use-os para alinhar modelos com responsabilidade durante o pré-treinamento contínuo.

Avaliações: tarefas de avaliações comparativas estão disponíveis para testar a capacidade do modelo de detectar e rejeitar conteúdo impróprio, prejudicial ou incorreto. Use essas avaliações para analisar a diferença entre a performance do modelo de base e a do modelo personalizado.

Treinamento para modelos do Amazon Nova

O treinamento de modelos do Amazon Nova no SageMaker HyperPod é compatível com várias técnicas, incluindo pré-treinamento contínuo (CPT), ajuste fino supervisionado (SFT) e ajuste fino por reforço (RFT). Cada técnica atende a diferentes necessidades de personalização e pode ser aplicada a diferentes versões de modelos do Amazon Nova.

Tópicos

- [Pré-treinamento contínuo \(CPT\)](#)
- [Ajuste fino supervisionado \(SFT\)](#)

- [Ajuste fino por reforço \(RFT\) no SageMaker HyperPod](#)

Pré-treinamento contínuo (CPT)

O pré-treinamento contínuo (CPT) é uma técnica de treinamento que estende a fase de pré-treinamento de um modelo de base, expondo-o a texto adicional sem rótulo de domínios ou corpora específicos. Ao contrário do ajuste fino supervisionado, que requer pares de entrada-saída rotulados, o CPT treina em documentos brutos para ajudar o modelo a adquirir um conhecimento mais profundo de novos domínios, aprender a terminologia e os padrões de escrita específicos do domínio e se adaptar a determinados tipos de conteúdo ou áreas temáticas.

Essa abordagem é particularmente valiosa quando você tem grandes volumes (dezenas de bilhões de tokens) de dados de texto específicos do domínio, como documentos legais, literatura médica, documentação técnica ou conteúdo comercial proprietário, e deseja que o modelo desenvolva fluência nativa nesse domínio. Geralmente, após a etapa do CPT, o modelo precisa passar por etapas adicionais de ajuste de instruções para permitir que o modelo use o conhecimento recém-adquirido e conclua tarefas úteis.

Modelos compatíveis

O CPT está disponível para os seguintes modelos do Amazon Nova:

- Nova 1.0 (Micro, Lite, Pro)
- Nova 2.0 (Lite)

Quando usar o Nova 1.0 versus o Nova 2.0

A família de modelos do Amazon Nova oferece vários pontos operacionais de relação preço/performance para otimizar entre precisão, velocidade e custo.

Escolha o Nova 2.0 quando você precisar do seguinte:

- Recursos avançados de raciocínio para tarefas analíticas complexas
- Desempenho superior em codificação, matemática e resolução de problemas científicos
- Suporte a janelas de contexto mais longas
- Melhor desempenho multilíngue

Note

O modelo maior nem sempre é melhor. Considere a relação custo-performance e seus requisitos comerciais específicos ao escolher entre os modelos Nova 1.0 e Nova 2.0.

CPT no Nova 2.0

O Amazon Nova Lite 2.0 é um modelo de raciocínio treinado em um conjunto de dados maior e mais diversificado do que o Nova Lite 1.0. Apesar de ser um modelo maior, o Nova Lite 2.0 oferece inferência mais rápida do que o Nova Lite 1.0, ao mesmo tempo em que oferece recursos aprimorados de raciocínio, janelas de contexto mais longas e melhor desempenho multilíngue.

O CPT no Nova 2.0 permite que você estenda esses recursos avançados com seus dados específicos de domínio, permitindo que o modelo desenvolva uma profunda experiência em áreas especializadas, mantendo suas habilidades superiores de raciocínio e análise.

Exemplo de fórmula de CPT

Confira a seguir um exemplo de fórmula de CPT. Você pode encontrar essa fórmula e outras no repositório de [fórmulas](#).

```
# 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
  global_batch_size: 256
  32, 64, 128, 256.

  trainer:
    max_steps: 10
    total
    val_check_interval: 10
    validation. Integer count or float percentage
    limit_val_batches: 2
    each trigger

  model:
    hidden_dropout: 0.0
    between 0.0 and 1.0
    attention_dropout: 0.0
    be between 0.0 and 1.0

  optim:
    optimizer: adam
    lr: 1e-5
    name: distributed_fused_adam
    adam_w_mode: true
    eps: 1e-06
    weight_decay: 0.0
    between 0.0 and 1.0
    adam_beta1: 0.9
    adam_beta2: 0.95
    sched:
      warmup_steps: 10
      constant_steps: 0
      min_lr: 1e-6
    than lr

```

Maximum context window size (tokens)

Global batch size, allowed values are

The number of training steps to run

The number of steps between running

Batches of the validation set to use

Dropout for hidden states, must be

Dropout for attention weights, must

Learning rate

Optimizer algorithm, do not change

Enable AdamW mode

Epsilon for numerical stability

L2 regularization strength, must be

Beta1 for Adam optimizer

Beta2 for Adam optimizer

Learning rate warmup steps

Steps at constant learning rate

Minimum learning rate, must be lower

Preparação de dados para CPT no 2.0

Requisitos de formato de dados

Os conjuntos de dados de treinamento e validação devem ser arquivos JSONL seguindo o formato mostrado abaixo, em que cada linha contém um objeto JSON representando uma conversa com a estrutura e os campos necessários. Aqui está um exemplo:

```
{"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"}
```

As entradas de texto devem ter um conteúdo de alta qualidade que flua naturalmente e represente seu domínio de destino.

Teste se os dados podem ser convertidos no [formato Arrow](#). Use o script Python abaixo para ajudar com essa ação. Certifique-se de que, no mínimo, a versão `datasets==2.18.0` seja usada:

```
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)
```

Ele deve imprimir o mesmo número de linhas que estavam no arquivo JSONL.

Ao usar o `datamixing`, execute a primeira tarefa com `max_steps=2`. Isso ajudará a criar otimizações no cluster para acesso aos dados e a validar se todos os `datamixes` estão disponíveis.

Como preparar dados para o CPT

Os dados de treinamento são o fator determinante mais importante para o sucesso do pré-treinamento contínuo. Embora os dados do CPT sejam frequentemente descritos como “sem rótulo”, a realidade é muito mais sutil. A forma como os dados são estruturados, formatados e apresentados determina se o modelo vai adquirir o conhecimento e as habilidades necessárias para o caso de uso do negócio.

Preparação de conjuntos de dados empresariais estruturados para CPT

É um desafio comum para empresas e organizações que criam modelos de base especializados em seu domínio. A maioria das empresas possui repositórios robustos de dados estruturados: catálogos de produtos, perfis de usuários, logs de transações, envios de formulários, chamadas de API e metadados operacionais. À primeira vista, isso parece ser muito diferente em relação aos textos não estruturados da web, comumente utilizados no pré-treinamento padrão.

Para aprender de forma eficaz com dados empresariais estruturados, pense cuidadosamente nas tarefas downstream e projete a apresentação dos dados para forçar o modelo a aprender as relações preditivas corretas.

Para o aproveitamento total do potencial do pré-treinamento contínuo, considere:

- Quais tarefas o modelo deve realizar no momento da inferência
- Quais informações estão presentes nos dados brutos
- Como estruturar esses dados para que o modelo aprenda a extrair e manipular as informações corretamente

Simplesmente despejar dados estruturados no treinamento não ensinará o modelo a raciocinar sobre isso. Molde ativamente a apresentação dos dados para orientar o que o modelo aprende.

Nas seções a seguir, há uma revisão da literatura que demonstra a importância do aumento de dados e fornece exemplos de estratégias de aumento para dados comerciais estruturados que fornecerão ideias úteis sobre como tratar e organizar o conjunto de dados de negócios para o CPT.

Dados estruturados para o CPT na literatura

O CPT pode incluir fatos de domínio no modelo, mas geralmente falha em tornar esses fatos recuperáveis e manipuláveis quando as entradas ou tarefas mudam. Experimentos controlados mostram que, sem um aumento diverso durante o pré-treinamento, os modelos memorizam fatos de maneiras frágeis que permanecem difíceis de extrair mesmo após o ajuste posterior das instruções, e recomendam injetar sinais semelhantes a instruções no início do treinamento. Para dados semiestruturados, a serialização randomizada e outros aumentos reduzem o sobreajuste do esquema, e é por isso que o CPT deve ser intercalado com tarefas de estilo de instrução em vez de ser executado primeiro e o IFT depois. Trabalhos com foco em finanças indicam que a combinação conjunta de dados de CPT e de instrução no momento do lote promove a melhoria da generalização e a redução do esquecimento em comparação ao método sequencial. O relatório técnico da Qwen

converge para o mesmo padrão ao integrar dados de instrução de alta qualidade ao próprio pré-treinamento, o que aumenta o aprendizado contextual e preserva o acompanhamento das instruções enquanto adquire novos conhecimentos de domínio.

O aumento de dados para corpora semiestruturadas é uma alavanca fundamental. O CPT com reconhecimento de gráficos sintéticos expande pequenos conjuntos de domínios em corpora vinculados a entidades que ensinam explicitamente relações e compostos com recuperação em tempo de inferência. A combinação conjunta de CPT e instruções apresenta desempenho superior a pipelines sequenciais em finanças, e o equilíbrio entre dados de domínio e dados gerais promove a redução da degradação de habilidades gerais. O CPT de domínio de altíssima escala também pode manter uma ampla capacidade e até mesmo permitir compensações por meio da mesclagem de modelos, mas ainda aponta o ajuste de instruções como uma próxima etapa essencial, reforçando o valor da introdução de sinais de instrução durante o CPT.

Injeção de diversidade por meio de randomização e embaralhamento

Uma estratégia geral que ajuda a ensinar o modelo de forma eficaz dos conjuntos de dados estruturados e semiestruturados é alterar a ordem dos campos nos conjuntos de dados e também excluir de forma randomizada algumas chaves.

Embaralhar os campos força o modelo a ler o que cada valor significa em vez de onde ele aparece e a aprender as relações entre todos os campos. Por exemplo, no caso de um videogame publicado na loja da Amazon, em que “Título”, “Plataforma”, “Preço”, “Condição” e “Edição” apresentam ordens variadas, o modelo fica impedido de utilizar a dependência posicional, como a suposição de que a “terceira posição corresponde à plataforma”; ele deve vincular rótulos a valores e aprender as relações bilaterais entre atributos: título $\rightleftharpoons$ plataforma, plataforma $\rightleftharpoons$ preço, condição $\rightleftharpoons$ preço. Assim, ele pode, por exemplo, inferir uma plataforma provável do nome de um jogo e de um preço observado, ou estimar uma faixa de preço plausível considerando um título e uma plataforma.

O descarte randomizado de chaves durante a serialização atua como um descarte de recursos: evita a coadaptação em qualquer campo e força o modelo a recuperar as informações perdidas das evidências restantes. Se “Plataforma” estiver ausente, o modelo deverá retirá-la da string de título ou do texto de compatibilidade; se “Preço” estiver oculto, ele deverá triangular da plataforma, edição e condição. Essa abordagem cria simetria ($A \rightarrow B$ e $B \rightarrow A$), robustez diante de listagens confusas do mundo real e invariância de esquema quando os campos estão ausentes, renomeados ou reordenados.

Um exemplo de estilo de compra torna isso concreto. Serialize o mesmo item de várias maneiras (“Título: ‘Elden Ring’ | Plataforma: PlayStation 5 | Condição: Usado - Como novo | Preço: USD 34,99”

e uma permutação como “Preço: USD 34,99 | Título: ‘Elden Ring’ | Condição: Usado - Como novo | Plataforma: PlayStation 5”) e, em certas iterações, omite “Plataforma” deixando “Compatível com PS5” na descrição. Treine objetivos complementares, como predição da plataforma de {title, price} e estimativa de um bucket de preços de {title, platform}. Como a ordem e até mesmo a presença das chaves variam, a única estratégia estável é aprender as verdadeiras relações entre os atributos em vez de memorizar um modelo.

A forma como os dados são apresentados é importante

O aprendizado de LLMs ocorre por meio da predição do próximo token com base no conteúdo previamente processado. Portanto, a ordem dos campos e eventos mostrados durante o treinamento decide o que o modelo pode aprender. Se o formato do treinamento corresponder à tarefa real, a perda incidirá sobre os tokens de decisão exatos. Se os campos forem agrupados sem estrutura, o modelo aprenderá atalhos ou memorizará a popularidade e, em seguida, falhará quando solicitado a escolher entre as opções.

Mostre primeiro a situação, depois as opções e então a decisão. Se o modelo também precisar aprender sobre resultados ou explicações, coloque-os após a decisão.

Exemplos de empacotamento de dados para o CPT

O que é empacotamento de dados?

Significa simplesmente preencher cada janela de sequência nos dados de treinamento com vários exemplos completos para que a janela fique densa com tokens reais, não com preenchimento.

Por que isso importa?

Durante o treinamento, um tamanho máximo de contexto é definido, por exemplo, 8.192 tokens. Os lotes são moldados para [tamanho do lote × extensão do contexto]. Se um exemplo de treinamento for menor que a extensão do contexto, as posições restantes serão preenchidas. O preenchimento mantém a execução via kernels de atenção e MLP, ainda que haja o mascaramento da função de perda, então a computação é paga por tokens que não transmitem nenhum sinal de aprendizado.

Como realizar o empacotamento de dados?

Para empacotar várias amostras, concatene vários exemplos de treinamento com um separador [DOC] entre eles (observe o espaço antes e depois do [DOC]) de forma que a extensão total dos exemplos permaneça abaixo da extensão de contexto desejada.

Um exemplo de documento empacotado seria assim:


```
{"text": "training sample 1 [DOC] training sample 2 [DOC] training sample 3"}
```

Parâmetros de ajuste do CTP

Os parâmetros que estão disponíveis para ajuste com o CPT incluem:

Configuração da execução

- **name:** um nome descritivo para a tarefa de treinamento. Isso ajuda a identificar sua tarefa no Console de Gerenciamento da AWS.
- **model_type:** a variante do modelo do Amazon Nova a ser usada. As opções disponíveis são `amazon.nova-2-lite-v1:0:256k`.
- **model_name_or_path:** o caminho para o modelo de base a ser usado em seu treinamento. As opções disponíveis são `nova-lite-2/prod` ou o caminho do S3 para o ponto de verificação pós-treinamento (`s3://customer-escrow-bucket-unique_id/training_run_name`).
- **replicas:** o número de instâncias de computação a serem usadas no treinamento distribuído. Os valores disponíveis variam de acordo com o modelo escolhido. O Amazon Nova Lite 2.0 é compatível com 4, 8, 16 ou 32 réplicas.
- **data_s3_path:** o local no S3 do conjunto de dados de treinamento, que é um arquivo JSONL. Esse arquivo deve residir na mesma conta e região da AWS que o cluster. Todos os locais do S3 fornecidos devem estar na mesma conta e região.
- **validation_data_s3_path:** (opcional) o local no S3 do conjunto de dados de validação, que é um arquivo JSONL. Esse arquivo deve estar na mesma conta e região que o cluster. Todos os locais do S3 fornecidos devem estar na mesma conta e região.
- **output_s3_path:** o local do S3 onde o manifesto e os logs do TensorBoard são armazenados. Todos os locais do S3 fornecidos devem estar na mesma conta da AWS e região da AWS.
- **mlflow_tracking_uri:** o ARN da aplicação MLFlow a ser usada para registro em log do MLFlow
- **mlflow_experiment_name:** nome do experimento do MLFlow
- **mlflow_run_name:** nome de execução do MLFlow

Configuração do treinamento

- **max_length:** o tamanho máximo da sequência em tokens. Isso determina o tamanho da janela de contexto para treinamento. O valor máximo permitido é 8.192 tokens para CPT.

Sequências mais longas melhorarão a eficiência do treinamento à custa de maiores requisitos de memória. Recomendamos que você faça a correspondência do parâmetro `max_length` com sua distribuição de dados.

- `global_batch_size`: o número total de exemplos de treinamento processados juntos em uma única etapa de propagação (forward ou backward) em todos os dispositivos e operadores.

Esse valor multiplica o tamanho do lote por dispositivo e o número de dispositivos. Isso afeta a estabilidade do treinamento e o throughput. Recomendamos que você comece com um tamanho de lote que caiba confortavelmente na memória e possa ter a escala aumentada verticalmente a partir daí. Para dados específicos do domínio, lotes maiores podem suavizar demais os gradientes.

Configurações do Trainer

- `max_steps`: o número de etapas de treinamento a serem executadas. Cada etapa treinará o modelo com o número de elementos `global_batch_size`

Configurações do modelo

- `hidden_dropout`: a probabilidade de descartar saídas de estados ocultos. Aumente esse valor em aproximadamente 0,0-0,2 para reduzir o sobreajuste em conjuntos de dados menores. Os valores válidos estão entre 0 e 1, inclusive.
- `attention_dropout`: a probabilidade de descartar pesos de atenção. Esse parâmetro pode ajudar na generalização. Os valores válidos estão entre 0 e 1, inclusive.

Configuração do otimizador

- `lr`: a taxa de aprendizado, que controla o tamanho da etapa durante a otimização. Recomendamos valores entre 1e-6 e 1e-4 para um obter bom desempenho. Os valores válidos estão entre 0 e 1, inclusive.
- `name`: o algoritmo otimizador. No momento, só há compatibilidade com `distributed_fused_adam`.
- `weight_decay`: a força de regularização de L2. Valores mais altos (entre 0,01 e 0,1) aumentam a regularização.

- `warmup_steps`: o número de etapas para aumentar gradualmente a taxa de aprendizado. Isso melhora a estabilidade do treinamento. Os valores válidos estão entre 1 e 20, inclusive.
- `min_lr`: a taxa mínima de aprendizado ao término do decaimento. Os valores válidos estão entre 0-1, inclusive, mas devem ser menores que a taxa de aprendizado.

Ajuste fino supervisionado (SFT)

O processo de treinamento do SFT consiste em duas etapas principais:

- **Preparação de dados**: siga as diretrizes estabelecidas para criar, limpar ou reformatar conjuntos de dados na estrutura necessária. Certifique-se de que as entradas, saídas e informações auxiliares (como metadados e rastros de raciocínio) estejam alinhadas e formatadas adequadamente.
- **Configuração de treinamento**: defina como o modelo será treinado. Essa configuração é gravada em um arquivo de fórmula YAML que inclui:
 - Caminhos da fonte de dados (conjuntos de dados de treinamento e validação)
 - Hiperparâmetros principais (épocas, taxa de aprendizado, tamanho do lote)
 - Componentes opcionais (parâmetros de treinamento distribuídos etc.)

Comparação e seleção de modelos Nova

O Amazon Nova 2.0 é um modelo treinado em um conjunto de dados maior e mais diversificado do que o Amazon Nova 1.0. Os principais aprimoramentos são:

- Habilidades de raciocínio aprimoradas com suporte explícito ao modo de raciocínio
- Performance multilíngue mais ampla em outros idiomas
- Performance aprimorada em tarefas complexas, incluindo codificação e uso de ferramentas
- Manipulação de contexto estendido com melhor precisão e estabilidade em textos de longa extensão

Quando usar o Nova 1.0 versus o Nova 2.0

Escolha o Amazon Nova 2.0 quando:

- É necessário um desempenho superior com recursos avançados de raciocínio
- É necessário suporte multilíngue ou gerenciamento de tarefas complexas

- São necessários melhores resultados em codificação, chamada de ferramentas ou tarefas analíticas

SFT no Nova 2.0

O Amazon Nova Lite 2.0 traz recursos aprimorados para ajuste fino supervisionado, incluindo modo de raciocínio avançado, melhor compreensão multimodal e tratamento de contexto estendido. O SFT no Nova 2.0 permite que você adapte esses recursos avançados aos seus casos de uso específicos, mantendo o desempenho superior do modelo em tarefas complexas.

Os principais recursos do SFT no Nova 2.0 incluem:

- Suporte ao modo de raciocínio: treine modelos para gerar rastros de raciocínio explícitos antes das respostas finais para aprimorar as capacidades analíticas.
- Treinamento multimodal avançado: ajuste a compreensão de documentos (PDF), a compreensão de vídeos e as tarefas baseadas em imagens com maior precisão.
- Recursos de chamada de ferramentas: treine modelos para usar ferramentas externas e chamadas de funções de forma eficaz em fluxos de trabalho complexos.
- Compatibilidade com contexto estendido: aproveite janelas de contexto mais longas com melhor estabilidade e precisão para aplicações com uso intensivo de documentos.

Note

Para obter mais informações sobre quais imagens de contêineres ou exemplos de fórmulas usar, acesse [Fórmulas do Amazon Nova](#).

Tópicos

- [Seleção do modo de raciocínio \(somente Nova 2.0\)](#)
- [Formato de dados de chamada de ferramentas](#)
- [Formato de dados para compreensão de documentos](#)
- [Compreensão de vídeos para o SFT](#)
- [Instruções de upload de dados](#)
- [Criação de uma tarefa de ajuste fino](#)
- [Parâmetros de ajuste do SFT](#)

- [Orientações de hiperparâmetros](#)

Exemplo de fórmula do SFT

Confira abaixo um exemplo de fórmula para o SFT. Você pode encontrar essa fórmula e outras no repositório de [fórmulas](#).

```
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
```

Seleção do modo de raciocínio (somente Nova 2.0)

O Amazon Nova 2.0 é compatível com o modo de raciocínio para recursos analíticos aprimorados:

- Modo de raciocínio (habilitado):
 - Definir `reasoning_enabled: true` na configuração de treinamento
 - O modelo treina para gerar rastros de raciocínio antes das respostas finais
 - Melhora o desempenho em tarefas complexas de raciocínio
- Modo sem raciocínio (desabilitado):
 - Definir `reasoning_enabled: false` ou omitir o parâmetro (padrão)
 - SFT padrão sem raciocínio explícito
 - Adequado para tarefas que não se beneficiam do raciocínio passo a passo

Note

- Quando o raciocínio está habilitado, ele opera com alto esforço de raciocínio. Não há uma opção de baixo raciocínio para o SFT.
- O conteúdo de raciocínio multimodal não é compatível com o SFT. O modo de raciocínio se aplica a entradas somente de texto.

Uso do modo de raciocínio com conjuntos de dados sem raciocínio

É permitido treinar o Amazon Nova em um conjunto de dados sem raciocínio com `reasoning_enabled: true`. No entanto, isso pode fazer com que o modelo perca suas capacidades de raciocínio, pois o Amazon Nova aprende primariamente a gerar as respostas apresentadas nos dados sem aplicar o raciocínio.

Se estiver treinando o Amazon Nova em um conjunto de dados sem raciocínio, mas ainda quiser usar o raciocínio durante a inferência:

1. Desabilite o raciocínio durante o treinamento (`reasoning_enabled: false`)
2. Habilite o raciocínio posteriormente durante a inferência

Embora essa abordagem permita o raciocínio no momento da inferência, ela não garante um melhor desempenho em comparação com a inferência sem raciocínio.

Prática recomendada: habilite o raciocínio para treinamento e inferência ao usar conjuntos de dados de raciocínio, e desabilite-o para ambos ao usar conjuntos de dados sem raciocínio.

Note

Para obter mais informações sobre quais imagens de contêineres ou exemplos de fórmulas usar, acesse [Fórmulas do Amazon Nova](#).

Formato de dados de chamada de ferramentas

O SFT é compatível com modelos de treinamento para usar ferramentas (chamada de função). Confira abaixo um exemplo de formato de entrada para chamada de ferramentas:

Exemplo de entrada:

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

Considerações importantes sobre dados de chamada de ferramentas:

- O ToolUse deve aparecer somente nos turnos do assistente
- O ToolResult deve aparecer somente nos turnos do usuário
- O ToolResult deve ser somente texto ou JSON; atualmente, outras modalidades não são compatíveis com os modelos do Amazon Nova
- O inputSchema dentro no toolSpec deve ser um objeto de esquema JSON válido
- Cada ToolResult deve fazer referência a um toolUseId válido de um assistente ToolUse anterior, com cada toolUseId usado exatamente uma vez por conversa

 Note

Para obter mais informações sobre quais imagens de contêineres ou exemplos de fórmulas usar, acesse [Fórmulas do Amazon Nova](#).

Formato de dados para compreensão de documentos

O SFT é compatível com modelos de treinamento em tarefas de compreensão de documentos. Confira abaixo um exemplo de formato de entrada:

Exemplo de entrada

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

Considerações importantes sobre a compreensão de documentos:

- Somente arquivos PDF são compatíveis
- O tamanho máximo do documento é de 10 MB
- Um exemplo pode conter documentos e texto, mas não pode misturar documentos com outras modalidades (como imagens ou vídeo)

Note

Para obter mais informações sobre quais imagens de contêineres ou exemplos de fórmulas usar, acesse [Fórmulas do Amazon Nova](#).

Compreensão de vídeos para o SFT

O SFT é compatível com modelos de ajuste fino para tarefas de compreensão de vídeo. Confira abaixo um exemplo de formato de entrada:

Exemplo de entrada

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

Considerações importantes sobre compreensão de vídeos:

- Os vídeos podem ter um máximo de 50 MB
- Os vídeos podem ter até 15 minutos de duração
- Somente um vídeo é permitido por exemplo; não há compatibilidade com vários vídeos no mesmo exemplo
- Um exemplo pode conter vídeo e texto, mas não pode misturar vídeo com outras modalidades (como imagens ou documentos)

 Note

Para obter mais informações sobre quais imagens de contêineres ou exemplos de fórmulas usar, acesse [Fórmulas do Amazon Nova](#).

Instruções de upload de dados

Faça upload de conjuntos de dados de treinamento e validação para um bucket do S3. Especifique esses locais no bloco run da fórmula:

```
## Run config
run:
  ...
  data_s3_path: "s3://<bucket-name>/<training-directory>/<training-file>.jsonl"
```

Observação: substitua <bucket-name>, <training-directory>, <validation-directory>, <training-file> e <validation-file> por caminhos reais do S3.

Observação: no momento, os conjuntos de dados de validação não são compatíveis com o SFT com o Amazon Nova 2.0. Se um conjunto de dados de validação for fornecido, ele será ignorado.

Criação de uma tarefa de ajuste fino

Defina o modelo base usando os campos `model_type` e `model_name_or_path` no bloco run:

```
## Run config
run:
  ...
  model_type: amazon.nova-2-lite-v1:0:256k
  model_name_or_path: nova-lite-2/prod
  ...
```

Parâmetros de ajuste do SFT

Os parâmetros que estão disponíveis para ajuste com o SFT incluem:

Configuração da execução

- **name:** um nome descritivo para a tarefa de treinamento. Isso ajuda a identificar sua tarefa no Console de Gerenciamento da AWS.
- **model_type:** a variante do modelo do Amazon Nova a ser usada. As opções disponíveis são `amazon.nova-2-lite-v1:0:256k`.
- **model_name_or_path:** o caminho para o modelo de base a ser usado em seu treinamento. As opções disponíveis são `nova-lite-2/prod` ou o caminho do S3 para o ponto de verificação pós-treinamento (`s3://customer-escrow-bucket-unique_id/training_run_name`).
- **replicas:** o número de instâncias de computação a serem usadas no treinamento distribuído. Os valores disponíveis variam de acordo com o modelo escolhido. O Amazon Nova Lite 2.0 é compatível com 4, 8, 16 ou 32 réplicas.
- **data_s3_path:** o local no S3 do conjunto de dados de treinamento, que é um arquivo JSONL. Esse arquivo deve residir na mesma conta e região da AWS que o cluster. Todos os locais do S3 fornecidos devem estar na mesma conta e região.
- **validation_data_s3_path:** (opcional) o local no S3 do conjunto de dados de validação, que é um arquivo JSONL. Esse arquivo deve estar na mesma conta e região que o cluster. Todos os locais do S3 fornecidos devem estar na mesma conta e região.
- **output_s3_path:** o local do S3 onde o manifesto e os logs do TensorBoard são armazenados. Todos os locais do S3 fornecidos devem estar na mesma conta da AWS e região da AWS.
- **mlflow_tracking_uri:** o ARN da aplicação MLFlow a ser usada para o registro em log do MLFlow.
- **mlflow_experiment_name:** nome do experimento do MLFlow.
- **mlflow_run_name:** nome de execução do MLFlow.

Configuração do treinamento

- **max_steps:** o número de etapas de treinamento a serem executadas. Cada etapa treinará o modelo com a quantidade de elementos definida no `global_batch_size`.
- **save_steps:** a frequência (em etapas) na qual os pontos de verificação do modelo são salvos durante o treinamento.
- **save_top_k:** o número máximo dos melhores pontos de verificação a serem retidos com base nas métricas de validação.
- **max_length:** o tamanho máximo da sequência em tokens. Isso determina o tamanho da janela de contexto para treinamento. O valor máximo permitido é 32.768 tokens para o SFT.

Sequências mais longas melhorarão a eficiência do treinamento à custa de maiores requisitos de memória. Recomendamos que você faça a correspondência do parâmetro `max_length` com sua distribuição de dados.

- `global_batch_size`: o número total de exemplos de treinamento processados juntos em uma única etapa de propagação (forward ou backward) em todos os dispositivos e operadores.

Esse valor multiplica o tamanho do lote por dispositivo e o número de dispositivos. Isso afeta a estabilidade do treinamento e o throughput. Recomendamos que você comece com um tamanho de lote que caiba confortavelmente na memória e possa ter a escala aumentada verticalmente a partir daí. Para dados específicos do domínio, lotes maiores podem suavizar demais os gradientes.

- `reasoning_enabled`: sinalizador booleano para habilitar recursos de raciocínio durante o treinamento.

Programador da taxa de aprendizado

- `warmup_steps`: o número de etapas para aumentar gradualmente a taxa de aprendizado. Isso melhora a estabilidade do treinamento.
- `min_lr`: a taxa mínima de aprendizado ao término do decaimento. Os valores válidos estão entre 0-1, inclusive, mas devem ser menores que a taxa de aprendizado.

Configuração do otimizador

- `lr`: a taxa de aprendizado, que controla o tamanho da etapa durante a otimização. Recomendamos valores entre $1e-6$ e $1e-4$ para um obter bom desempenho. Os valores válidos estão entre 0 e 1, inclusive.
- `weight_decay`: a força de regularização de L2. Valores mais altos (entre 0,01 e 0,1) aumentam a regularização.
- `adam_beta1`: a taxa de decaimento exponencial para as estimativas do primeiro momento no otimizador Adam. O padrão é de 0.9.
- `adam_beta2`: a taxa de decaimento exponencial para as estimativas do segundo momento no otimizador Adam. A padrão é 0.95.

Configuração do PEFT

- `peft_scheme`: o esquema de ajuste fino com eficiência de parâmetros a ser usado. As opções são `'null'` para ajuste fino de full-rank ou `lora` para ajuste fino baseado em LoRA.

Ajuste LoRA (quando `peft_scheme` é `'lora'`)

- `alpha`: o parâmetro de escala LoRA. Controla a magnitude da adaptação de low-rank. Os valores típicos variam de 8 a 128.
- `lora_plus_lr_ratio`: a taxa de aprendizado para a otimização via LoRA+. Esse multiplicador ajusta a taxa de aprendizado especificamente para os parâmetros LoRA.

Orientações de hiperparâmetros

Use os seguintes hiperparâmetros recomendados com base na abordagem de treinamento:

Treinamento de full-rank

- Épocas: 1
- Taxa de aprendizado (`lr`): $1e-5$
- Taxa mínima de aprendizado (`min_lr`): $1e-6$

LoRA (Low-Rank Adaptation)

- Épocas: 2
- Taxa de aprendizado (`lr`): $5e-5$
- Taxa mínima de aprendizado (`min_lr`): $1e-6$

Observação: ajuste esses valores com base no tamanho do conjunto de dados e no desempenho da validação. Monitore as métricas de treinamento para evitar sobreajuste.

Ajuste fino por reforço (RFT) no SageMaker HyperPod

O ajuste fino por reforço (RFT) é uma técnica de machine learning que melhora o desempenho do modelo por meio de sinais de feedback (pontuações mensuráveis ou recompensas indicando a qualidade da resposta) em vez de supervisão direta com respostas corretas exatas. Ao contrário do ajuste fino supervisionado tradicional que aprende com pares de entrada e saída, o RFT usa

funções de recompensa para avaliar as respostas do modelo e otimiza iterativamente o modelo para maximizar essas recompensas.

Essa abordagem é particularmente eficaz para tarefas em que definir a saída exata correta é um desafio, mas você pode avaliar com segurança a qualidade da resposta. O RFT permite que os modelos aprendam comportamentos e preferências complexos por meio de testes e feedback, tornando-os ideais para aplicações que exigem uma tomada de decisão diferenciada, solução criativa de problemas ou adesão a critérios de qualidade específicos que podem ser avaliados de forma programática.

Quando usar o RFT

Use o RFT quando você puder definir critérios de sucesso claros e mensuráveis, mas tiver dificuldade em fornecer resultados exatos e corretos para o treinamento. É ideal para tarefas em que a qualidade é subjetiva ou multifacetada, como escrita criativa, otimização de código ou raciocínio complexo, em que existem várias soluções válidas, mas algumas são claramente melhores do que outras.

O RFT funciona melhor quando você tem o seguinte:

- Uma função de recompensa confiável que pode avaliar as saídas do modelo de forma programática
- Necessidade de alinhar o comportamento do modelo com preferências ou restrições específicas
- Situações em que o ajuste fino supervisionado tradicional é insuficiente porque coletar exemplos rotulados de alta qualidade é caro ou impraticável

Considere o RFT para aplicações que exigem aprimoramento iterativo, personalização ou adesão a regras de negócios complexas que podem ser codificadas como sinais de recompensa.

Casos de uso ideais para o RFT

O RFT se destaca em domínios em que a qualidade da saída pode ser avaliada objetivamente, mas as respostas ideais são difíceis de definir de antemão:

- Resolução de problemas matemáticos: verificabilidade da exatidão por meio de diversos caminhos de resolução
- Geração e otimização de código: resultados de execução testáveis e métricas de desempenho
- Tarefas de raciocínio científico: consistência lógica e precisão factual

- Análise de dados estruturados: saídas verificáveis programaticamente
- Raciocínio em várias etapas: tarefas que exigem progressão lógica passo a passo
- Uso de ferramentas e chamadas de API: sucesso mensurável pelos resultados da execução
- Fluxos de trabalho complexos: adesão a restrições e regras de negócios específicas

O RFT funciona excepcionalmente bem quando você precisa equilibrar vários objetivos concorrentes, como precisão, eficiência e estilo.

Quando usar o modo de raciocínio para o treinamento via RFT

O Amazon Nova 2.0 é compatível com o modo de raciocínio durante o treinamento via RFT. Os seguintes modos estão disponíveis:

- none: sem raciocínio (omite o campo `reasoning_effort`)
- low: sobrecarga mínima de raciocínio
- high: capacidade máxima de raciocínio (padrão quando `reasoning_effort` é especificado)

 Note

Não há a opção medium para o RFT. Se o campo `reasoning_effort` estiver ausente da sua configuração, o raciocínio será desabilitado.

Use raciocínio high para o seguinte:

- Tarefas analíticas complexas
- Resolução de problemas matemáticos
- Dedução lógica de várias etapas
- Tarefas em que o pensamento passo a passo agrega valor

Use o raciocínio low ou none (omite `reasoning_effort`) para o seguinte:

- Consultas factuais simples
- Classificações diretas
- Velocidade e otimização de custos

- Respostas diretas a perguntas

Important

Modos de raciocínio mais altos aumentam o tempo e o custo do treinamento bem como a latência e o custo da inferência, mas também aumentam a capacidade do modelo para tarefas complexas de raciocínio.

Modelos compatíveis

O RFT onSageMaker HyperPod é compatível com o Amazon Nova Lite 2.0 (amazon.nova-2-lite-v1:0:256k).

Principais etapas

O processo de RFT envolve quatro fases principais:

- Implementação de um avaliador: crie uma função de recompensa para pontuar programaticamente as respostas do modelo com base em seus critérios de qualidade.
- Carregamento de prompts: prepare e carregue dados de treinamento no formato conversacional específico com dados de referência para avaliação.
- Início de uma tarefa: inicie o processo de ajuste fino por reforço com seus parâmetros configurados.
- Monitoramento: acompanhe o progresso do treinamento por meio de painéis de métricas para garantir que o modelo aprenda de forma eficaz.

Cada etapa se baseia na anterior, com o avaliador servindo como base que orienta todo o processo de treinamento, fornecendo sinais de feedback consistentes.

Tópicos

- [RFT no Nova 2.0](#)

RFT no Nova 2.0

Os dados de treinamento de RFT seguem o formato conversacional da OpenAI. Cada exemplo de treinamento é um objeto JSON que contém mensagens, respostas de referência e definições de

ferramentas opcionais. Esta seção fornece orientação sobre como preparar dados de treinamento eficazes para RFT no Nova 2.0.

Tópicos

- [Formato e estrutura de dados](#)
- [Descrições do campo](#)
- [Orientações de hiperparâmetros](#)
- [Propriedades adicionais](#)
- [Recomendações de tamanho do conjunto de dados](#)
- [Características dos dados de treinamento efetivos](#)
- [Monitoramento do treinamento de RFT](#)

Formato e estrutura de dados

Cada exemplo de treinamento é um objeto JSON que contém o seguinte:

- **messages:** uma matriz de turnos de conversação usando perfis de sistema, usuário e, opcionalmente, de assistente
- **reference_answer:** resultado esperado ou critérios de avaliação para o cálculo da recompensa
- **tools (opcional):** matriz de definições de funções disponíveis para o modelo
- **id (opcional):** identificador único para rastreamento e deduplicação

Cada exemplo deve estar em uma única linha no arquivo JSONL, com um objeto JSON por linha.

Exemplo 1: problema de química

O seguinte exemplo mostra um problema de química com uma resposta de referência contendo valores de verdade fundamental:

```
{
  "id": "chem-001",
  "messages": [
    {
      "role": "system",
      "content": "You are a helpful chemistry assistant"
    },
  ],
}
```

```
{
  "role": "user",
  "content": "Predict hydrogen bond donors and acceptors for this SMILES:
CCN(CC)CCC(=O)c1sc(N)nc1C"
},
"reference_answer": {
  "donor_bond_counts": 2,
  "acceptor_bond_counts": 4,
  "explanation": "Calculated using Lipinski's rule of five: N-H groups (2 donors), N
and O atoms with lone pairs (4 acceptors)"
}
}
```

Note

O `reference_answer` contém valores de verdade fundamental calculados usando regras específicas do domínio. Sua função de recompensa compara os valores de predição do modelo com esses valores de referência para calcular uma pontuação de recompensa.

Exemplo 2: problema de matemática

O seguinte exemplo mostra um problema de matemática com etapas de solução:

```
{
  "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": [" $2x = 13 - 5$ ", " $2x = 8$ ", " $x = 4$ "]
  }
}
```

Exemplo 3: uso da ferramenta

O exemplo a seguir mostra o uso da ferramenta com o comportamento esperado:

```
{
  "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"
  }
}

```

Descrições do campo

Campo	Descrição	Notas adicionais	Obrigatório
id	Identificador único para este exemplo de RFT	String (por exemplo, "sample-001"). Útil para rastreamento e deduplicação.	Não
mensagens	Lista ordenada de mensagens de chat que definem o prompt e o contexto	Matriz de objetos . O modelo os vê em ordem. Normalmente começa com uma mensagem do sistema, e depois o usuário.	Sim
messages[].role	Quem está falando na mensagem	Valores comuns: "system", "user" (às vezes "assistant" em outros contextos)	Não
messages[].content	O conteúdo do texto da mensagem	String simples. Para o sistema, são as instruções, para o usuário, é a tarefa ou a entrada.	Não
ferramentas	Especificações da ferramenta disponíveis para o modelo durante este exemplo	Matriz. Cada item define a interface e os metadados de uma ferramenta. Os tipos podem incluir	Não

Campo	Descrição	Notas adicionais	Obrigatório
		“function” ou “internal”.	
reference_answer	A saída esperada do modelo para este exemplo	String ou objeto, dependendo da tarefa. Usado como destino para avaliação ou treinamento.	Não

Note

Todos os campos personalizados adicionais (por exemplo, task_id, difficulty_level, context_data) não são validados e serão passados para sua função de recompensa como metadados.

Orientações de hiperparâmetros

Use os seguintes hiperparâmetros recomendados com base em sua abordagem de treinamento:

Geral:

- Épocas: 1
- Taxa de aprendizado (lr): 1e-7
- Número de gerações: 8
- Máximo de novos tokens: 8.192
- Tamanho do lote: 256

LoRA (Low-Rank Adaptation):

- Classificação LoRA: 32

 Note

Ajuste os valores com base no tamanho do conjunto de dados e no desempenho de validação. Monitore as métricas de treinamento para evitar sobreajuste.

Propriedades adicionais

A configuração “additionalProperties”: true permite que você inclua campos personalizados além dos requisitos principais do esquema, oferecendo flexibilidade para adicionar quaisquer dados de que sua função de recompensa precise para uma avaliação adequada.

Campos adicionais comuns

Você pode incluir os seguintes tipos de campos adicionais:

Metadados:

- task_id: identificador único de rastreamento
- difficulty_level: indicador de complexidade do problema
- domain: área ou categoria do assunto
- expected_reasoning_steps: número de etapas na solução

Critérios de avaliação:

- evaluation_criteria: parâmetros de classificação específicos
- custom_scoring_weights: importância relativa de diferentes aspectos
- context_data: informações contextuais sobre o problema
- external_references: links para documentação ou recursos relevantes

Exemplo com propriedades adicionais

O seguinte exemplo inclui campos de metadados personalizados:

```
{  
  "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
}
```

Recomendações de tamanho do conjunto de dados

Ponto de partida

Comece com os seguintes tamanhos mínimos de conjunto de dados:

- Mínimo de 100 exemplos de treinamento
- Mínimo de 100 exemplos de avaliação

Priorize dados de entrada de alta qualidade e uma função de recompensa confiável que seja executada de forma consistente nas respostas do modelo.

Abordagem que prioriza a avaliação

Antes de investir em treinamento de RFT em grande escala, avalie o desempenho básico do seu modelo:

- Alto desempenho (recompensa superior a 95%): o RFT pode ser desnecessário, pois seu modelo já tem um bom desempenho
- Desempenho muito baixo (0% de recompensa): mude primeiro para o SFT para estabelecer os recursos básicos
- Desempenho moderado: o RFT provavelmente é apropriado

Essa abordagem que prioriza a avaliação garante que sua função de recompensa esteja livre de erros e determine se o RFT é o método certo para seu caso de uso. Começar aos poucos permite que você se familiarize com o fluxo de trabalho do RFT, identifique e corrija problemas com antecedência, valide sua abordagem antes de aumentar a escala verticalmente e teste a confiabilidade da função de recompensa. Depois de validado, você pode expandir para conjuntos de dados maiores para melhorar ainda mais o desempenho.

Características dos dados de treinamento efetivos

Clareza e consistência

Bons exemplos de RFT exigem dados de entrada claros e inequívocos que permitam o cálculo preciso da recompensa em diferentes saídas do modelo. Evite ruídos em seus dados, incluindo:

- Formatação inconsistente
- Rótulos ou instruções contraditórios
- Prompts ambíguos
- Respostas de referência conflitantes

Qualquer ambiguidade induzirá o processo de treinamento ao erro, fazendo com que o modelo aprenda comportamentos indesejados.

Diversidade

Seu conjunto de dados deve capturar toda a diversidade de casos de uso de produção para garantir um desempenho robusto no mundo real. Inclusão:

- Vários tipos de problemas e níveis de dificuldade
- Diferentes formatos de entrada e casos de borda
- Exemplos representativos de todos os cenários esperados

Essa diversidade ajuda a evitar o sobreajuste e garante que o modelo processe entradas desconhecidas de forma resiliente.

Considerações sobre a função de recompensa

Projete sua função de recompensa para um treinamento eficiente:

- Execute em segundos (não em minutos)

- Paralelize de forma eficaz com o Lambda
- Retorne pontuações consistentes e confiáveis
- Lide com diferentes tipos de saídas de modelo de forma resiliente

As funções de recompensa rápidas e escaláveis permitem uma iteração rápida e uma experimentação econômica em grande escala.

Monitoramento do treinamento de RFT

Monitore as principais métricas durante o treinamento para garantir um aprendizado eficaz e identificar possíveis problemas com antecedência.

Tópicos

- [Principais métricas a serem acompanhadas](#)
- [Avaliação após o RFT](#)
- [Uso de modelos ajustados](#)
- [Limitações e práticas recomendadas](#)
- [Solução de problemas](#)

Principais métricas a serem acompanhadas

Monitore as seguintes métricas usando o MLFlow durante o treinamento:

Métricas de recompensa:

- Pontuação média de recompensa: qualidade geral das respostas do modelo (deve aumentar com o tempo)
- Distribuição de recompensas: porcentagem de respostas que receberam recompensas altas, médias e baixas
- Recompensas de treinamento vs. validação: compare para detectar sobreajuste

Métricas de treinamento:

- Atualizações da política: número de atualizações de peso bem-sucedidas
- Taxa de conclusão da distribuição: porcentagem de amostras avaliadas com êxito

Padrões de atenção:

- Estabilização das recompensas (indica aprendizado deficiente)
- As recompensas de validação diminuem enquanto as recompensas de treinamento aumentam (sobreajuste)
- A variação da recompensa aumenta significativamente ao longo do tempo (instabilidade)
- Alta porcentagem de erros na função de recompensa (problemas de implementação)

Quando parar de treinar:

- As métricas de desempenho alvo foram alcançadas
- As recompensas se estabilizaram e não melhoram mais
- O desempenho da validação está degradando (detectado sobreajuste)
- O orçamento máximo de treinamento foi atingido

Avaliação após o RFT

Após a conclusão do treinamento, avalie seu modelo ajustado para avaliar as melhorias de desempenho:

- Execute a tarefa de avaliação de RFT: use o ponto de verificação do seu treinamento de RFT como modelo
- Compare com a linha de base: avalie o modelo de base e o modelo ajustado no mesmo conjunto de testes
- Analise métricas: analise as métricas específicas da tarefa (precisão, pontuações de recompensa etc.)
- Realize uma análise qualitativa: inspecione manualmente as saídas da amostra quanto à qualidade

Para obter os procedimentos de avaliação detalhados, consulte a seção Avaliação.

Uso de modelos ajustados

Acesso aos pontos de verificação:

Após a conclusão do treinamento, localize seu ponto de controle:

1. Navegue até o seu `output_path` no S3
2. Faça download e extraia `output.tar.gz`
3. Abra o `manifest.json`
4. Copie o valor `checkpoint_s3_bucket`

Implantação para inferência:

Use o caminho do ponto de verificação do S3 para inferência ou treinamento adicional:

```
run:
  model_type: amazon.nova-2-lite-v1:0:256k
  model_name_or_path: "s3://customer-escrow-<account-number>-smtj-<unique-
  identifier>/<job-name>"
```

Para instruções de implantação e inferência, consulte a seção Inferência.

Limitações e práticas recomendadas

Limitações atuais:

Restrições beta:

- É necessário criar um novo grupo RIG para o RFT. Essa limitação será resolvida pela GA.
- Requisitos de tipo de instância: somente instâncias P5 são compatíveis (mínimo 8x P5.48xlarge). Em breve: compatibilidade com tipos de instâncias menores (ETA: meados de janeiro de 2025).

Limitações funcionais:

- Tempo limite de 15 minutos do Lambda: as funções de recompensa devem ser concluídas em até 15 minutos
- Somente em um único turno: conversas em vários turnos não são compatíveis
- Conjuntos de dados de validação: não há compatibilidade durante o treinamento. Use trabalhos de avaliação separados para avaliar o progresso do treinamento.

Considerações sobre treinamento:

- Cenários de baixa recompensa: podem ter dificuldades quando menos de 5% dos exemplos recebem recompensas positivas; considere primeiro o SFT

- Requisitos de dados: precisa de diversidade suficiente para aprender de forma eficaz
- Custo computacional: mais caro do que o ajuste fino supervisionado

O Nova Forge remove algumas dessas limitações:

- É compatível com conversas em vários turnos
- Permite funções de recompensa que excedem o tempo limite de 15 minutos
- Fornece algoritmos avançados e opções de ajuste
- Projetado para casos de uso corporativo complexos, especificamente ajustado para criar modelos de fronteira

Práticas recomendadas:

Começar pequeno e escalar:

- Comece com conjuntos de dados mínimos (100 a 200 exemplos) e poucas épocas de treinamento
- Valide sua abordagem antes de aumentar a escala verticalmente
- Aumente gradualmente o tamanho do conjunto de dados e as etapas de treinamento com base nos resultados

Definir a linha de base com o SFT primeiro:

- Se as pontuações de recompensa forem consistentemente baixas (por exemplo, sempre 0), execute o SFT antes do RFT
- O RFT requer um desempenho de linha de base razoável para melhorar de forma eficaz

Criar funções de recompensa eficientes:

- Execute em segundos, em vez de em minutos
- Minimize as chamadas de API externas
- Use algoritmos e estruturas de dados eficientes
- Implemente o tratamento adequado de erros
- Teste completamente antes de treinar
- Aproveite os recursos de escalabilidade paralela do Lambda

Monitorar ativamente o treinamento:

- Acompanhe as pontuações médias de recompensa ao longo do tempo
- Assista à distribuição de recompensas em todas as amostras
- Compare as recompensas de treinamento vs. validação
- Procure padrões de atenção (estabilizações, sobreajuste, instabilidade)

Fazer iterações com base nos resultados:

- Se as recompensas não melhorarem após várias iterações, ajuste o design da função de recompensa
- Aumente a diversidade do conjunto de dados para fornecer sinais de aprendizado mais claros
- Considere mudar para o SFT se as recompensas permanecerem próximas de zero
- Experimente com diferentes hiperparâmetros (taxa de aprendizado, tamanho do lote)

Otimizar a qualidade dos dados:

- Garanta exemplos diversos e representativos
- Inclua casos de borda e exemplos difíceis
- Verifique se a função de recompensa pontua corretamente todos os tipos de exemplo
- Remova ou corrija exemplos que confundem a função de recompensa

Solução de problemas

Erros da função de recompensa:

Sintomas: alta taxa de erro nas chamadas da função de recompensa durante o treinamento

Problema	Sintomas	Resolução
tempo limite do Lambda	Tempos limite frequentes após 15 minutos	Otimize o desempenho da função; considere o Nova Forge para avaliações complexas

Problema	Sintomas	Resolução
Simultaneidade insuficiente	Erros de controle de utilização do Lambda	Aumente o <code>lambda_concurrency_limit</code> ou solicite um aumento de cota
Formato de retorno inválido	O treinamento falha com erros de formato	Verifique se a estrutura de retorno corresponde ao formato de interface necessário
Exceções não tratadas	Erros intermitentes	Inclua registro em log e um tratamento de erros abrangente
Falhas de API externas	Pontuação inconsistente	Implemente a lógica de novas tentativas e estratégias de fallback

Baixo desempenho no treinamento:

Sintomas: as recompensas não melhoram ou se estabilizam em valores baixos

Soluções:

- Verifique a exatidão da função de recompensa: teste com exemplos bons/ruins conhecidos
- Verifique o desempenho da linha de base: avalie o modelo de base; se a precisão estiver próxima de zero, realize o SFT primeiro
- Aumente a diversidade de dados: adicione exemplos mais variados abrangendo diferentes cenários
- Ajuste os hiperparâmetros: experimente diferentes taxas de aprendizado ou tamanhos de lote
- Analise a qualidade do sinal de recompensa: garanta que as recompensas diferenciem entre respostas boas e ruins

Sobreajuste:

Sintomas: as recompensas de treinamento aumentam enquanto as recompensas de validação diminuem

Soluções:

- Reduza as etapas de treinamento: pare de treinar antecipadamente
- Aumente o tamanho do conjunto de dados: adicione mais exemplos de treinamento
- Adicione regularização: ajuste `weight_decay` ou `entropy_coeff`
- Aumente a diversidade de dados: garanta que o conjunto de treinamento represente uma distribuição completa

Avaliar o modelo treinado

Uma receita de avaliação é um arquivo de configuração YAML que define como a tarefa de avaliação de modelo do Amazon Nova é executada. Com essa receita, você pode avaliar a performance de um modelo básico ou treinado em relação a benchmarks comuns ou em relação a seus próprios conjuntos de dados personalizados. As métricas podem ser armazenadas no Amazon S3 ou no TensorBoard. A avaliação fornece métricas quantitativas que ajudam a avaliar a performance do modelo em várias tarefas para determinar se é necessária alguma personalização adicional.

A avaliação de modelo é um processo off-line em que os modelos são testados em relação a benchmarks fixos com respostas predefinidas. Eles não são avaliados em tempo real ou em relação às interações ao vivo do usuário. Para avaliações em tempo real, você pode avaliar o modelo depois de implantado no Amazon Bedrock chamando as APIs de runtime do Amazon Bedrock.

Tópicos

- [Tarefas de referência disponíveis](#)
- [Noções básicas sobre parâmetros de fórmula](#)
- [Exemplos de fórmula de avaliação](#)
- [Iniciar um trabalho de avaliação](#)
- [Acessar e analisar os resultados da avaliação](#)
- [Avaliação de RFT](#)

Tarefas de referência disponíveis

Um pacote de código de amostra está disponível para demonstrar como calcular métricas de referência usando o recurso de avaliação de modelo do SageMaker AI para o Amazon Nova. Para acessar os pacotes de código, consulte [sample-Nova-lighteval-custom-task](#).

Veja aqui uma lista de referências padrão do setor disponíveis e compatíveis. É possível especificar as seguintes referências no parâmetro `eval_task`:

Referência	Modalidade	Descrição	Métricas	Estratégia	Subtarefa disponível
mmlu	Texto	Compreensão de linguagem multitarefa: testa o conhecimento em 57 disciplinas.	accuracy	zs_cot	Sim
mmlu_pro	Texto	MMLU (subconjunto profissional): concentra-se em domínios profissionais como direito, medicina, contabilidade e engenharia.	accuracy	zs_cot	Não
bbh	Texto	Tarefas de raciocínio avançado: um conjunto de problemas desafiadores	accuracy	zs_cot	Sim

Referência	Modalidade	Descrição	Métricas	Estratégia	Subtarefa disponível
		que testam habilidades cognitivas e de resolução de problemas de nível mais alto.			
gpqa	Texto	Resposta a perguntas de física geral: avalia a compreensão de conceitos de física e habilidades relacionadas à resolução de problemas .	accuracy	zs_cot	Não
math	Texto	Resolução de problemas matemáticos: mede o raciocínio matemático em vários tópicos, como álgebra, cálculo e problemas de palavras.	exact_match	zs_cot	Sim

Referência	Modalidade	Descrição	Métricas	Estratégia	Subtarefa disponível
strong_reject	Texto	Tarefa de controle de qualidade : testa a capacidade do modelo de detectar e rejeitar conteúdo impróprio, prejudicial ou incorreto.	deflection	zs	Sim
IFEval	Texto	Avaliação de seguimento de instruções: avalia com que precisão um modelo segue as instruções dadas e conclui as tarefas conforme as especificações.	accuracy	zs	Não

Referência	Modalidade	Descrição	Métricas	Estratégia	Subtarefa disponível
gen_qa	Texto	Avaliação personalizada do conjunto de dados: permite que você utilize seu próprio conjunto de dados para fins de avaliação comparativa, comparando as saídas do modelo para respostas de referência com métricas como ROUGE e BLEU.	todas	gen_qa	Não

Referência	Modalidade	Descrição	Métricas	Estratégia	Subtarefa disponível
llm_judge	Texto	Comparação de preferências do LLM como avaliador: usa um modelo avaliador do Amazon Nova para determinar a preferência entre respostas emparelhadas (B em comparação com A) para os prompts, calculando a probabilidade de B ser preferencial em relação a A.	todas	avaliador	Não

Referência	Modalidade	Descrição	Métricas	Estratégia	Subtarefa disponível
humaneval	Texto	HumanEval: um conjunto de dados de referência projetado para avaliar as capacidades de geração de código de grandes modelos de linguagem.	passar@1	zs	Não
mm_llm_judge	Multimodal (imagem)	Esta nova avaliação comparativa se comporta da mesma forma que o llm_judge baseado em texto acima. A única diferença é que ele é compatível com a inferência de imagens.	todas	avaliador	Não

Referência	Modalidade	Descrição	Métricas	Estratégia	Subtarefa disponível
rubric_llm_judge	Text	O Rubric Judge é um modelo aprimorado de avaliação LLM como avaliador criado no Amazon Nova 2.0 Lite. Ao contrário do modelo original do avaliador , que fornece apenas veredictos preferenciais, o Rubric Judge gera dinamicamente critérios de avaliação personalizados para cada prompt e atribui pontuações granulares em várias dimensões.	todas	avaliador	Não

Referência	Modalidade	Descrição	Métricas	Estratégia	Subtarefa disponível
aime_2024	Text	AIME 2024: problemas do American Invitational Mathematics Examination que testam raciocínio matemático avançado e resolução de problemas	exact_match	zs_cot	No
calendar_scheduling	Text	Natural Plan: agendamento de calendário, tarefa de teste de habilidades de planejamento para marcar reuniões de vários dias e com várias pessoas	exact_match	fs	No

As seguintes subtarefas mmlu estão disponíveis:

```
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"  
]
```

As seguintes subtarefas bbh estão disponíveis:

```
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"  
]
```

As seguintes subtarefas math estão disponíveis:

```
MATH_SUBTASKS = [  
    "algebra",  
    "counting_and_probability",  
    "geometry",  
    "intermediate_algebra",  
    "number_theory",  
    "prealgebra",  
    "precalculus",  
]
```

Noções básicas sobre parâmetros de fórmula

Configuração da execução

A seguir está uma configuração geral de execução e uma explicação sobre os parâmetros envolvidos.

```
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:** (obrigatório) um nome descritivo para sua tarefa de avaliação. Isso ajuda a identificar sua tarefa no Console da AWS.
- **model_type:** (obrigatório) Especifica a variante do modelo do Amazon Nova a ser usada. Não modifique manualmente esse campo. Entre as opções estão:
 - `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`: (obrigatório) o caminho para o modelo de base ou o caminho do S3 para o ponto de verificação pós-treinado. Entre as opções estão:
 - `nova-micro/prod`
 - `nova-lite/prod`
 - `nova-pro/prod`
 - `nova-lite-2/prod`
 - (Caminho S3 para o ponto de verificação pós-treinado) `s3://<escrow bucket>/<job id>/outputs/checkpoints`
- `replicas`: (obrigatório) o número de instâncias de computação a serem usadas no treinamento distribuído. Você deve definir esse valor como 1 porque não é possível usar vários nós.
- `data_s3_path`: (obrigatório) o caminho do S3 para o conjunto de dados de entrada. Deixe esse parâmetro vazio, a menos que você esteja usando o traga seu próprio conjunto de dados ou o LLM como avaliador.
- `output_s3_path`: (obrigatório) o caminho do S3 para armazenar artefatos de avaliação de saída. Observe que o bucket de saída do S3 deve ser criado pela mesma conta que está criando a tarefa.
- `mlflow_tracking_uri`: (opcional) ARN do servidor de rastreamento MLflow para rastrear execuções/experimentos do MLflow. Certifique-se de ter permissão para acessar o servidor de rastreamento no perfil de execução do SageMaker AI

Configuração da avaliação

A seguir é apresentada uma configuração avaliação de modelo e uma explicação sobre os parâmetros envolvidos.

```
evaluation:
  task: mmlu
  strategy: zs_cot
  subtask: mathematics
  metric: accuracy
```

- `task`: (obrigatório) especifica a referência ou tarefa de avaliação a ser usada.

Lista de tarefas compatíveis:

- `mmlu`
- `mmlu_pro`

- `bbh`
- `gpqa`
- `math`
- `strong_reject`
- `gen_qa`
- `ifeval`
- `llm_judge`
- `humaneval`
- `mm_llm_judge`
- `rubric_llm_judge`
- `aime_2024`
- `calendar_scheduling`
- `humaneval`
- `strategy`: (obrigatório) define a abordagem de avaliação.
 - `zs_cot`: cadeia de pensamento zero shot, uma abordagem de utilização de prompts em grandes modelos de linguagem que incentiva o raciocínio passo a passo sem exigir exemplos explícitos.
 - `zs`: zero shot, uma abordagem para resolver um problema sem nenhum exemplo de treinamento prévio.
 - `gen_qa`: uma estratégia específica para trazer suas próprias fórmulas de conjuntos de dados.
 - `judge`: uma estratégia específica para o LLM como avaliador do Amazon Nova.
- `subtask`: (opcional e removível) estipula uma subtarefa específica para determinadas tarefas de avaliação. Remova da sua fórmula se sua tarefa não tiver subtarefas.
- `metric`: (obrigatório) a métrica de avaliação a ser usada.
 - `accuracy`: porcentagem de respostas corretas.
 - `exact_match`: (para a referência `math`) exibe a taxa na qual as strings previstas de entrada correspondem exatamente às respectivas referências.
 - `deflection`: (para a referência `strong_reject`), exibe a deflexão relativa ao modelo base e a diferença nas métricas de significância.
 - `pass@1`: (para a referência `humaneval`) é uma métrica usada para medir a porcentagem de casos em que a predição de maior confiança do modelo corresponde à resposta correta.

- Para a referência `gen_qa` e trazer seu próprio conjunto de dados, exibe as seguintes métricas:
 - `rouge1`: mede a sobreposição de unigramas (palavras únicas) entre o texto gerado e o texto de referência.
 - `rouge2`: mede a sobreposição de unigramas (duas palavras consecutivas) entre o texto gerado e o texto de referência.
 - `rougeL`: mede a maior subsequência comum entre textos, permitindo lacunas na correspondência.
 - `exact_match`: pontuação binária (0 ou 1) indicando se o texto gerado corresponde exatamente ao texto de referência, caractere por caractere.
 - `quasi_exact_match`: semelhante à correspondência exata, mas mais tolerante. Geralmente ignora diferenças de maiúsculas e minúsculas, pontuação e espaço em branco.
 - `f1_score`: média harmônica de precisão e recall. Mede a sobreposição de palavras entre as respostas previstas e de referência.
 - `f1_score_quasi`: semelhante ao `f1_score`, mas com uma correspondência mais branda. Usa a comparação de texto normalizada que ignora pequenas diferenças.
 - `bleu`: mede a precisão das correspondências de n-gramas entre o texto gerado e o texto de referência. É comumente usada em avaliação de tradução.
- Para `llm_judge` e `mm_llm_judge`, utilize seu próprio conjunto de dados de avaliação comparativa e obtenha as seguintes métricas:
 - `a_scores`: número de acertos da `response_A` em passagens de avaliação para frente e para trás.
 - `a_scores_stderr`: erro padrão de `response_A` scores em avaliações de pares.
 - `b_scores`: número de acertos da `response_B` em passagens de avaliação para frente e para trás.
 - `b_scores_stderr`: erro padrão de `response_B` scores em avaliações de pares.
 - `ties`: número de avaliações em que a `response_A` e a `response_B` são avaliadas como iguais.
 - `ties_stderr`: erro padrão de empates em avaliações de pares.
 - `inference_error`: contagem de avaliações que não puderam ser concluídas adequadamente.
 - `inference_error_stderr`: erro padrão de erros de inferência em todas as avaliações.

- `score`: pontuação agregada com base nos acertos dos passes para frente e para trás da `response_B`.
- `score_stderr`: erro padrão da pontuação agregada em avaliações de pares.
- `winrate`: a probabilidade de que a `response_B` será preferida em relação à `response_A` calculada por meio da probabilidade de Bradley-Terry.
- `lower_rate`: limite inferior (2,5º percentil) da taxa de acerto estimada da amostragem de bootstrap.

Configuração de inferência

A seguir é apresentada uma configuração de inferência e uma explicação sobre os parâmetros envolvidos. Todos os parâmetros são opcionais.

```
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`: o número máximo de tokens a serem gerados. Deve ser um número inteiro.
- `top_k`: o número de tokens de maior probabilidade a serem considerados. Deve ser um número inteiro.
- `top_p`: o limite de probabilidade cumulativa para a amostragem de tokens. Deve ser um número de ponto flutuante entre 0,0 e 1,0, inclusive.
- `temperature`: aleatoriedade na seleção de tokens. Valores maiores aumentam a aleatoriedade. Use 0 que os resultados sejam determinísticos. Esse valor deve ser um número de ponto flutuante com um valor mínimo de 0.
- `top_logprobs`: o número dos principais logprobs a serem retornados na resposta de inferência. O valor deve ser um número inteiro de 0 a 20. Os logprobs contêm os tokens de saída considerados e as probabilidades logarítmicas de cada token de saída retornado no conteúdo da mensagem.
- `reasoning_effort`: controla o comportamento de raciocínio para modelos capazes de raciocinar. Defina `reasoning_effort` somente quando `model_type` especificar um modelo

capaz de raciocínio (atualmente `amazon.nova-2-lite-v1:0:256k`). As opções disponíveis são `null` (valor padrão se não definido; desabilita o raciocínio), `low` ou `high`.

Observe que, para `humaneval`, recomendamos a seguinte configuração de inferência:

```
inference:
  top_k: 1
  max_new_tokens: 1600
  temperature: 0.0
```

Configuração do MLflow

Confira a seguir uma configuração do MLflow e uma explicação sobre os parâmetros envolvidos. Todos os parâmetros são opcionais.

```
run:
  mlflow_tracking_uri: ""
  mlflow_experiment_name: ""
  mlflow_run_name: ""
```

- `mlflow_tracking_uri`: (opcional) a localização do servidor de rastreamento MLflow (necessário somente no SMHP)
- `mlflow_experiment_name`: (opcional) nome do experimento para agrupar execuções de ML relacionadas
- `mlflow_run_name`: (opcional) nome personalizado para um treinamento específico executado em um experimento

Exemplos de fórmula de avaliação

O Amazon Nova oferece quatro tipos de fórmulas de avaliação, que estão disponíveis no repositório de fórmulas do SageMaker HyperPod no GitHub.

Fórmulas gerais de referência de texto

Essas fórmulas permitem que você avalie as capacidades fundamentais dos modelos do Amazon Nova em um conjunto abrangente de referências somente de texto. Elas são fornecidas no formato `xxx_general_text_benchmark_eval.yaml`.

Fórmulas de referência de traga seu próprio conjunto de dados

Essas fórmulas permitem que você traga seu próprio conjunto de dados para fins de avaliação comparativa e compare os resultados do modelo com as respostas de referência usando diferentes tipos de métrica. Elas são fornecidas no formato `xxx_bring_your_own_dataset_eval.yaml`.

A seguir são apresentados os requisitos para trazer seu próprio conjunto de dados:

- Requisitos de formato de arquivo
 - Você deve incluir um único arquivo `gen_qa.jsonl` contendo exemplos de avaliação.
 - Seu conjunto de dados deve ser carregado em um local do S3 onde a tarefa de treinamento do SageMaker possa acessá-lo.
 - O arquivo deve seguir o formato de esquema exigido para um conjunto de dados geral de perguntas e respostas.
- Requisitos de formato de esquema: cada linha do arquivo JSONL deve ser um objeto JSON com os seguintes campos:
 - `query`: (obrigatório) string contendo a pergunta ou instrução que precisa de uma resposta.
 - `response`: (obrigatório) string contendo a saída esperada do modelo.
 - `system`: (opcional) string contendo o prompt do sistema que define o comportamento, o perfil ou a personalidade do modelo de IA antes de processar a consulta.
 - `metadata`: (opcional) string contendo metadados associados à entrada para fins de marcação.

Este é um exemplo de entrada para trazer seu próprio conjunto de dados.

```
{
  "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": "What is the symbol that ends the sentence as a question",
  "response": "?"
}
```

```
"query": "Repeat only the last two words of the following: I ate a hamburger today  
and it was kind of dry",  
"response": "of dry"  
}
```

Para usar seu conjunto de dados personalizado, modifique sua fórmula de avaliação com os campos obrigatórios a seguir. Não altere nenhum conteúdo.

```
evaluation:  
  task: gen_qa  
  strategy: gen_qa  
  metric: all
```

As limitações a seguir se aplicam a:

- Somente um arquivo JSONL é permitido por avaliação.
- O arquivo deve seguir rigorosamente o esquema definido.
- Limite de tamanho do contexto: para cada amostra no conjunto de dados, o tamanho do contexto (incluindo prompts do sistema + consulta) deve ser inferior a 3,5 mil.

Fórmulas de referência de LLM como avaliador do Nova

O LLM como avaliador do Amazon Nova é um recurso de avaliação de modelo que permite aos clientes comparar a qualidade das respostas de um modelo com a resposta de um modelo de referência em um conjunto de dados personalizado. Ele usa um conjunto de dados com prompts, respostas de linha de base e respostas desafiadoras e usa um modelo avaliador do Amazon Nova para fornecer uma métrica de taxa de acertos com base na [probabilidade de Bradley-Terry](#) com comparações de pares.

As fórmulas são fornecidas no formato `xxx_llm_judge_eval.yaml`.

Estes são os requisitos do LLM como avaliador:

- Requisitos de formato de arquivo
 - Inclua um único arquivo `llm_judge.jsonl` contendo exemplos de avaliação. O nome do arquivo deve ser `llm_judge.jsonl`.
 - Seu conjunto de dados deve ser carregado em um local do S3 que o [RIG do SageMaker AI SageMaker HyperPod](#) possa acessar.

- O arquivo deve seguir o formato de esquema exigido para o conjunto de dados `llm_judge.jsonl`.
- O conjunto de dados de entrada deve garantir que todos os registros tenham menos de 12 mil de comprimento de contexto.
- Requisitos de formato de esquema: cada linha do arquivo JSONL deve ser um objeto JSON com os seguintes campos:
 - `prompt`: (obrigatório) uma string contendo o prompt para a resposta gerada.
 - `response_A`: uma string contendo a resposta de referência.
 - `response_B`: uma string contendo a resposta alternativa a ser comparada com a resposta de referência.

Este é um exemplo de entrada de LLM como avaliador.

```
{
  "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."
```

```
}
```

Para usar seu conjunto de dados personalizado, modifique a fórmula de avaliação com os campos obrigatórios a seguir. Não altere nenhum conteúdo.

```
evaluation:
  task: llm_judge
  strategy: judge
  metric: all
```

As limitações a seguir se aplicam a:

- Somente um arquivo JSONL é permitido por avaliação.
- O arquivo deve seguir rigorosamente o esquema definido.
- Os modelos avaliadores do Amazon Nova são os mesmos em todas as especificações da família de modelos (ou seja, Lite, Micro e Pro).
- No momento, não é possível usar modelos avaliadores.
- Limite de tamanho do contexto: para cada amostra no conjunto de dados, o tamanho do contexto (incluindo prompts do sistema + consulta) deve ser inferior a 7 mil.

LLM como avaliador do Nova para fórmulas de avaliações comparativas multimodais (imagem)

O LLM como avaliador para multimodais (imagem), ou simplesmente Amazon Nova MM_LLM como avaliador, é um recurso de avaliação de modelos que permite que você compare a qualidade das respostas de um modelo com as respostas de um modelo de linha de base usando um conjunto de dados personalizado. Ele aceita um conjunto de dados contendo prompts, respostas de linha de base, respostas desafiantes e imagens no formato de string codificada em Base64, e depois usa um modelo avaliador do Amazon Nova para fornecer uma métrica de taxa de acertos com base na probabilidade de [Bradley-Terry](#) por meio de comparações de pares. Formato da fórmula: `xxx_mm_llm_judge_eval.yaml`.

Requisitos do conjunto de dados do LLM do Nova

Formato do arquivo:

- Um único arquivo `mm_llm_judge.jsonl` contendo exemplos de avaliação. O nome do arquivo deve ser exatamente `llm_judge.jsonl`.

- Você deve fazer upload de seu conjunto de dados em um local do S3 que as tarefas de treinamento do SageMaker possam acessar.
- O arquivo deve seguir o formato de esquema exigido para o conjunto de dados `mm_11m_judge`.
- O conjunto de dados de entrada deve garantir que todos os registros estejam dentro do limite de 12 mil de contexto, excluindo o atributo da imagem.

Formato do esquema: cada linha no arquivo `.jsonl` deve ser um objeto JSON com os campos a seguir.

- Campos obrigatórios.

`prompt`: string contendo o prompt para a resposta gerada.

`images`: matriz contendo uma lista de objetos com atributos de dados (os valores são strings de imagens codificadas em Base64).

`response_A`: string contendo a resposta de referência.

`response_B`: string contendo a resposta alternativa a ser comparada com a resposta de referência.

Exemplo de entrada

Para facilitar a leitura, o exemplo a seguir inclui novas linhas e recuo, mas no conjunto de dados real, cada registro deve estar em uma única linha.

```
{
  "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",
}
```

Para usar seu conjunto de dados personalizado, modifique a fórmula de avaliação com os campos obrigatórios a seguir. Não altere nenhum conteúdo.

```
evaluation:
  task: mm_llm_judge
  strategy: judge
  metric: all
```

Limitações

- Somente um arquivo `.jsonl` é permitido por avaliação.
- O arquivo deve seguir rigorosamente o esquema definido.
- Os modelos Nova MM Judge são compatíveis apenas com a referência de imagem.
- Os modelos avaliadores MM são os mesmos nas especificações do Amazon Nova Lite.
- No momento, não há compatibilidade para modelos avaliadores.
- O URI de imagem do Amazon S3 não é compatível.
- O conjunto de dados de entrada deve garantir que todos os registros estejam dentro do limite de 12 mil de contexto, excluindo o atributo de imagens.

Rubric Based Judge

O Rubric Judge é um modelo aprimorado de avaliação LLM como avaliador criado no Amazon Nova 2.0 Lite. Ao contrário do [modelo original do avaliador](#), que fornece apenas veredictos de preferência (A>B, B>A ou empate), o Rubric Judge gera dinamicamente critérios de avaliação personalizados para cada prompt e atribui pontuações granulares em várias dimensões.

Principais recursos:

- Geração dinâmica de critérios: cria automaticamente dimensões de avaliação relevantes com base no prompt de entrada
- Pontuação ponderada: atribui pesos de importância a cada critério para refletir sua significância relativa
- Avaliação granular: fornece pontuações detalhadas em uma base binária (true/false) ou em escala (1–5) para cada critério
- Métricas de qualidade: calcula pontuações de qualidade contínuas (escala 0–1) que quantificam a magnitude das diferenças entre as respostas

Exemplo de critério gerado pelo modelo:

```
price_validation:
  description: "The response includes validation to ensure price is a positive value."
  type: "scale"
  weight: 0.3
```

O modelo avalia as duas respostas em relação a todos os critérios gerados e, em seguida, usa essas pontuações em nível de critério para informar sua decisão final de preferência.

Tópicos

- [Configuração de fórmula](#)
- [Formato do conjunto de dados de entrada](#)
- [Resultado da avaliação](#)
- [Suporte ao modelo de raciocínio](#)

Configuração de fórmula

Fórmula do Rubric Judge

Habilite o Rubric Judge definindo task: `rubric_llm_judge` em sua fórmula:

```
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)

```

Fórmula original do LLM como avaliador (para comparação)

O modelo original do avaliador usa task: llm_judge:

```

run:
  name: eval-job-name                       # [MODIFIABLE] Unique
  identifier for your evaluation job
  model_type: amazon.nova-micro-v1:0:128k  # [FIXED] Model type
  model_name_or_path: "nova-micro/prod"    # [FIXED] Path to model
  checkpoint or identifier
  replicas: 1                               # [MODIFIABLE] Number of
  replicas for SageMaker Training job
  data_s3_path: ""                           # [FIXED] Leave empty for
  SageMaker Training job
  output_s3_path: ""                         # [FIXED] Leave empty for
  SageMaker Training job

evaluation:
  task: llm_judge                           # [FIXED] Original judge task
  strategy: judge                           # [FIXED] Evaluation strategy

```

```

metric: all                                # [FIXED] Metric calculation
method

inference:
  max_new_tokens: 12000                    # [MODIFIABLE] Maximum tokens
  to generate
  top_k: -1                                # [MODIFIABLE] Top-k sampling
  parameter
  top_p: 1.0                               # [MODIFIABLE] Nucleus sampling
  parameter
  temperature: 0                           # [MODIFIABLE] Sampling
  temperature (0 = deterministic)

```

Formato do conjunto de dados de entrada

O formato do conjunto de dados de entrada é idêntico ao [modelo original do avaliador](#):

Campos obrigatórios:

- **prompt**: string contendo o prompt de entrada e as instruções
- **response_A**: string contendo a saída de linha de base do modelo
- **response_B**: string contendo a saída personalizada do modelo

Exemplo de conjunto de dados (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."}
```

Requisitos de formato:

- Cada entrada deve ser um objeto JSON de linha única
- Entradas separadas com novas linhas
- Siga a nomenclatura exata do campo, conforme mostrado nos exemplos

Resultado da avaliação

Estrutura de saída

O Rubric Judge gera métricas de avaliação aprimoradas em comparação com o modelo original do avaliador:

```
{
  "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"
}
}

```

Novas métricas no Rubric Judge

As seis métricas abaixo são exclusivas do Rubric Judge e fornecem uma avaliação granular da qualidade:

Métrica	Descrição
<code>weighted_score_A</code>	Pontuação média de qualidade normalizada para <code>response_A</code> em todos os critérios de avaliação gerados pelo modelo. As pontuações são ponderadas pela importância do critério e normalizadas para a escala 0–1 (maior = melhor qualidade)
<code>weighted_score_A_stderr</code>	Erro padrão da média para <code>weighted_score_A</code> , indicando incerteza estatística
<code>weighted_score_B</code>	Pontuação média de qualidade normalizada para <code>response_B</code> em todos os critérios de avaliação gerados pelo modelo. As pontuações são ponderadas pela importância do critério e normalizadas para a escala 0–1 (maior = melhor qualidade)

Métrica	Descrição
<code>weighted_score_B_stderr</code>	Erro padrão da média para <code>weighted_score_B</code> , indicando incerteza estatística
<code>score_margin</code>	Diferença entre as pontuações ponderadas (calculada como <code>weighted_score_A</code> - <code>weighted_score_B</code>). Intervalo: de -1,0 a 1,0. Positivo = <code>response_A</code> é melhor; negativo = <code>response_B</code> é melhor; próximo de zero = qualidade similar
<code>score_margin_stderr</code>	Erro padrão da média para <code>score_margin</code> , indicando incerteza na medição da diferença de qualidade

Noções básicas sobre as métricas de pontuação ponderada

Objetivo: pontuações ponderadas fornecem medições de qualidade contínuas que complementam os veredictos de preferência binária, permitindo uma visão mais profunda sobre a performance do modelo.

Principais diferenças em relação ao avaliador original:

- Avaliador original: gera apenas preferências discretas ($A > B$, $B > A$, $A = B$)
- Rubric Judge: gera preferências e pontuações de qualidade contínuas (escala 0–1) com base em critérios personalizados

Interpretação de `score_margin`:

- `score_margin` = -0.128: `response_B` obteve 12,8 pontos percentuais a mais do que `response_A`
- $|\text{score\_margin}| < 0.1$: diferença de qualidade mínima (decisão acirrada)
- $|\text{score\_margin}| > 0.2$: diferença clara de qualidade (decisão confiante)

Casos de uso:

- Melhoria do modelo: identifique áreas específicas em que seu modelo tem uma performance inferior
- Quantificação da qualidade: avalie a magnitude das lacunas de performance, não apenas as taxas de ganhos/perdas
- Avaliação de confiança: faça a distinção entre decisões acirradas e diferenças claras de qualidade

Important

Os veredictos finais ainda são baseados nos rótulos de preferência explícitos do modelo do avaliador para preservar o raciocínio holístico e garantir a mitigação adequada do viés de posição por meio de avaliação progressiva e retroativa. As pontuações ponderadas servem como ferramentas de observabilidade, não como substitutas do veredicto primário.

Metodologia de cálculo

As pontuações ponderadas são calculadas usando o seguinte processo:

- Extrair dados do critério: analise a saída YAML do avaliador para extrair pontuações e pesos do critério
- Normalize as pontuações:
 - Critérios do tipo de escala (1–5): normalize para 0–1 calculando $(\text{score} - 1) / 4$
 - Critérios binários (true/false): converter para 1,0/0,0
- Aplique pesos: multiplique cada pontuação normalizada pelo peso do critério
- Agregado: soma todas as pontuações ponderadas para cada resposta
- Calcular margem: calcular $\text{score\_margin} = \text{weighted\_score\_A} - \text{weighted\_score\_B}$

Exemplo: se response_A tiver uma soma ponderada de 0,65, e response_B tiver 0,78, score_margin seria -0,13, indicando que response_B tem 13 pontos percentuais a mais em qualidade em todos os critérios ponderados.

Suporte ao modelo de raciocínio

A compatibilidade com o modelo de raciocínio permite a avaliação com modelos do Amazon Nova capazes de raciocinar que realizam raciocínio interno explícito antes de gerar respostas finais. Esse recurso usa o controle em nível de API por meio do parâmetro reasoning_effort para habilitar ou

desabilitar dinamicamente a funcionalidade de raciocínio, melhorando potencialmente a qualidade da resposta para tarefas analíticas complexas.

Modelos compatíveis:

- amazon.nova-2-lite-v1:0:256k

Configuração de fórmula

Habilite o raciocínio adicionando o parâmetro `reasoning_effort` à seção `inference` da sua fórmula:

```
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
temperature (0 = deterministic)
```

[MODIFIABLE] Sampling

Uso do parâmetro reasoning_effort

O parâmetro reasoning_effort controla o comportamento do raciocínio para modelos capazes de raciocinar.

Pré-requisitos:

- Compatibilidade do modelo: defina reasoning_effort somente quando model_type especificar um modelo capaz de raciocínio (atualmente amazon.nova-2-lite-v1:0:256k)
- Tratamento de erros: o uso de reasoning_effort com modelos não compatíveis falhará com ConfigValidationError: "Reasoning mode is enabled but model '{model_type}' does not support reasoning. Please use a reasoning-capable model or disable reasoning mode."

Opções disponíveis:

Opção	Comportamento	Limite de tokens	Caso de uso
null (padrão)	Desabilita o modo de raciocínio	N/D	Avaliação padrão sem sobrecarga de raciocínio
low	Permite o raciocínio com restrições	4 mil tokens para raciocínio interno	Cenários que exigem raciocínio conciso; otimiza em termos de velocidade e custo
high	Permite o raciocínio sem restrições	Nenhum limite de token no raciocínio interno	Problemas complexos que exigem análise extensiva e raciocínio passo a passo

Quando habilitar o raciocínio

Use o modo de raciocínio (**low**, **medium** ou **high**) para:

- Tarefas complexas de resolução de problemas (cálculo, quebra-cabeças lógicos, codificação)
- Perguntas analíticas de várias etapas que exigem raciocínio intermediário
- Tarefas em que explicações detalhadas ou o raciocínio passo a passo melhoram a precisão
- Cenários em que a qualidade da resposta é priorizada em relação à velocidade

Use o modo sem raciocínio (omita o parâmetro) para:

- Perguntas e respostas simples ou consultas factuais
- Tarefas de escrita criativa
- Quando tempos de resposta mais rápidos são essenciais
- Avaliação comparativa de performance em que a sobrecarga de raciocínio deve ser excluída
- Otimização de custos quando o raciocínio não melhora a performance da tarefa

Solução de problemas

Erro: "o modo de raciocínio está habilitado, mas o modelo não é compatível com ele"

Causa: o parâmetro `reasoning_effort` está definido como um valor não nulo, mas o `model_type` especificado não é compatível com o raciocínio.

Resolução:

- Verifique se o tipo de modelo é `amazon.nova-2-lite-v1:0:256k`
- Se estiver usando um modelo diferente, mude para um modelo capaz de raciocinar ou remova o parâmetro `reasoning_effort` da sua fórmula

Iniciar um trabalho de avaliação

Veja a seguir um tipo de instância de avaliação e uma configuração do tipo de modelo:

```
# 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]
```

Você também deve poder visualizar o status do trabalho por meio do console de cluster do Amazon EKS.

Acessar e analisar os resultados da avaliação

Depois que seu trabalho de avaliação for concluído com êxito, você poderá acessar e analisar os resultados usando as informações nesta seção. Com base no `output_s3_path` (como `s3://output_path/`) definido na fórmula, a estrutura de saída é a seguinte:

```
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]
```

Os resultados das métricas são armazenados no local de saída `s3://output_path/job_name/eval-result/result-timestamp.json` especificado do S3.

Os resultados do TensorBoard são armazenados no caminho do S3 `s3://output_path/job_name/eval-tensorboard-result/eval/event.out.tfevents.epoch+ip`.

Todas as saídas de inferência, exceto `llm_judge` e `strong_reject`, são armazenadas no caminho do S3: `s3://output_path/job_name/eval-result/details/model/taskname.parquet`.

Para `gen_qa`, o arquivo `inference_output.jsonl` contém os seguintes campos para cada objeto JSON:

- `prompt`: o prompt final enviado ao modelo.
- `inferência`: a saída bruta de inferência do modelo.
- `gold`: a resposta esperada do conjunto de dados de entrada
- `metadata`: a string de metadados do conjunto de dados de entrada, se fornecida

Para visualizar suas métricas de avaliação no TensorBoard, conclua as seguintes etapas:

1. Navegue até o TensorBoard no SageMaker AI.

2. Selecione Pastas do S3.
3. Adicione o caminho da pasta do S3; por exemplo, `s3://output_path/job-name/eval-tensorboard-result/eval`.
4. Aguarde a conclusão da sincronização.

As visualizações de séries temporais, escalares e de texto estão disponíveis.

Recomendamos seguir estas práticas recomendadas:

- Mantenha seus caminhos de saída organizados por modelo e tipo de referência.
- Mantenha convenções de nomenclatura consistentes para facilitar o rastreamento.
- Salve os resultados extraídos em um local seguro.
- Monitore o status de sincronização do TensorBoard para garantir que os dados sejam carregados com êxito.

Você pode encontrar os logs de erros de tarefas do SageMaker HyperPod no grupo de logs `/aws/sagemaker/Clusters/cluster-id` do CloudWatch.

Formato de saída da probabilidade logarítmica

Quando `top_logprobs` está configurado em suas definições de inferência, o resultado da avaliação inclui probabilidades logarítmicas em nível de token nos arquivos parquet. Cada posição de token contém um dicionário dos principais tokens candidatos com suas probabilidades logarítmicas na seguinte estrutura:

```
{
  "Ġint": {"logprob_value": -17.8125, "decoded_value": " int"},
  "Ġthe": {"logprob_value": -2.345, "decoded_value": " the"}
}
```

Cada entrada de token contém:

- `logprob_value`: o valor da probabilidade logarítmica para o token
- `decoded_value`: a representação de string decodificada legível por humanos do token

O token bruto do tokenizador é usado como a chave do dicionário para garantir a exclusividade, enquanto `decoded_value` fornece uma interpretação legível.

Avaliação de RFT

Note

A avaliação por meio de funções de recompensa remotas em seu próprio ambiente da AWS só estará disponível se você for cliente do Amazon Nova Forge.

Important

O campo de configuração `rl_env` é usado exclusivamente para avaliação, não para treinamento. Durante o treinamento, você configura as funções de recompensa usando a infraestrutura `reward_lambda_arn` (turno único) ou BYOO com `rollout.delegate: true` (vários turnos).

O que é avaliação de RFT?

A avaliação de RFT permite que você avalie o desempenho do seu modelo usando funções de recompensa personalizadas antes, durante ou após o treinamento de aprendizado por reforço. Ao contrário das avaliações padrão que usam métricas predefinidas, a avaliação de RFT permite que você defina seus próprios critérios de sucesso por meio de uma função do Lambda que pontua os resultados do modelo com base em seus requisitos específicos.

Por que avaliar com o RFT?

A avaliação é crucial para determinar se o processo de ajuste fino do RL:

- Aprimorou o alinhamento de modelos com seu caso de uso específico e valores humanos
- Manteve ou aprimorou os recursos dos modelos nas principais tarefas
- Evitou efeitos colaterais indesejados, como redução da factualidade, aumento da verbosidade ou degradação do desempenho em outras tarefas
- Atendeu aos seus critérios de sucesso personalizados, conforme definido por sua função de recompensa

Quando usar a avaliação de RFT

Use a avaliação de RFT nestes cenários:

- Antes do treinamento de RFT: estabeleça métricas de linha de base em seu conjunto de dados de avaliação
- Durante o treinamento de RFT: monitore o progresso do treinamento com pontos de verificação intermediários
- Após o treinamento de RFT: valide se o modelo final atende aos seus requisitos
- Comparando modelos: avalie várias versões do modelo usando critérios de recompensa consistentes

Note

Use a avaliação de RFT quando precisar de métricas personalizadas e específicas do domínio. Para avaliação de propósito geral (precisão, perplexidade, BLEU), use métodos de avaliação padrão.

Tópicos

- [Requisitos de formato de dados](#)
- [Preparação da sua fórmula de avaliação](#)
- [Funções de recompensa predefinidas](#)
- [Criação da função de recompensa](#)
- [permissões do IAM](#)
- [Execução da tarefa de avaliação](#)
- [Conceitos básicos dos resultados da avaliação](#)

Requisitos de formato de dados

Estrutura de dados de entrada

Os dados de entrada da avaliação de RFT devem seguir o formato de ajuste fino por reforço da OpenAI. Cada exemplo é um objeto JSON que contém:

- `messages`: matriz de turnos de conversação com os perfis `system` e `user`
- Outros metadados opcionais, por exemplo, `reference_answer`

Exemplo de formato de dados

O seguinte exemplo mostra o formato correto:

```
{
  "messages": [
    {
      "role": "user",
      "content": [
        {
          "type": "text",
          "text": "Solve for x. Return only JSON like {\"x\": <number>}. Equation: 2x + 5 = 13"
        }
      ]
    }
  ],
  "reference_answer": {
    "x": 4
  }
}
```

Limitações atuais

As limitações a seguir se aplicam à avaliação de RFT:

- Somente texto: não há compatibilidade com entradas multimodais (imagens, áudio, vídeo)
- Conversas em um único turno: compatível apenas com mensagens de um único usuário (sem diálogos com vários turnos)
- Formato JSON: os dados de entrada devem estar no formato JSONL (um objeto JSON por linha)
- Saídas do modelo: a avaliação é realizada nas conclusões geradas do modelo específico

Preparação da sua fórmula de avaliação

Configuração do exemplo de fórmula

O exemplo a seguir mostra uma fórmula completa de avaliação de RFT:

```
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>

```

Funções de recompensa predefinidas

Duas funções de recompensa predefinidas (`prime_code` e `prime_math`) estão disponíveis como uma camada do Lambda para facilitar a integração com suas funções de RFT do Lambda.

Visão geral

Essas funções predefinidas fornecem recursos de avaliação prontos para uso para:

- `prime_code`: geração de código e avaliação da exatidão
- `prime_math`: raciocínio matemático e avaliação da resolução de problemas

Configuração rápida

Para usar funções de recompensa predefinidas:

1. Baixe a camada do Lambda das [versões nova-custom-eval-sdk](#)
2. Publique a camada do Lambda usando a 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. Adicione a camada à sua função do Lambda no Console da AWS (selecione preset-function-layer na camada personalizada e também adicione AWSSDKPandas-Python312 para dependências numpy)
4. Importe e use no seu código do Lambda:

```
from prime_code import compute_score # For code evaluation
from prime_math import compute_score # For math evaluation
```

função prime_code

Objetivo: avalia as tarefas de geração de código Python executando o código em casos de teste e avaliando a exatidão.

Exemplo de formato de conjunto de dados de entrada da avaliação:

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

Principais atributos:

- Extração automática de código de blocos de código markdown
- Detecção de funções e testes baseados em chamadas
- Execução de casos de teste com proteção de tempo limite

- Verificações de compilação e validação de sintaxe
- Relatórios detalhados de erros com rastreamentos

prime_math function

Objetivo: avalia o raciocínio matemático e as capacidades de resolução de problemas com suporte matemático simbólico.

Formato de entrada:

```
{"messages":[{"role":"user","content":"What is the derivative of x^2 + 3x?."}], "reference_answer":"2*x + 3"}
```

Principais atributos:

- Avaliação matemática simbólica usando SymPy
- Vários formatos de resposta (LaTeX, texto simples, simbólico)
- Verificação de equivalência matemática
- Simplificação e normalização da expressão

Práticas recomendadas

Siga estas práticas recomendadas ao usar funções de recompensa predefinidas:

- Use tipos de dados adequados em casos de teste (inteiros vs. strings, booleanos vs. "True")
- Forneça assinaturas de funções claras em problemas de código
- Inclua casos de borda nas entradas de teste (zero, números negativos, entradas vazias)
- Formate expressões matemáticas de forma consistente nas respostas de referência
- Teste sua função de recompensa com dados de exemplo antes da implantação

Criação da função de recompensa

ARN do Lambda

Você deve consultar o seguinte formato para o ARN do Lambda:

```
"arn:aws:lambda::*:function:*SageMaker"
```

Se o Lambda não tiver esse esquema de nomenclatura, a tarefa falhará com este erro:

```
[ERROR] Unexpected error: lambda_arn must contain one of: ['SageMaker', 'sagemaker', 'Sagemaker'] when running on SMHP platform (Key: lambda_arn)
```

Estrutura da função do Lambda

Sua função do Lambda recebe lotes de resultados de modelos e retorna pontuações de recompensa. Confira abaixo um exemplo de implementação:

```
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 de solicitação do Lambda

Sua função do Lambda recebe dados neste 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

A estrutura da mensagem inclui a matriz content aninhada, correspondente ao formato dos dados de entrada. A última mensagem com o perfil nova_assistant contém a resposta gerada pelo modelo.

Formato de resposta do Lambda

Sua função do Lambda deve retornar dados neste 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"  
      }  
    ]  
  }  
]
```

Campos de resposta:

- **id**: deve corresponder ao ID do exemplo de entrada
- **aggregate_reward_score**: pontuação geral (normalmente de 0,0 a 1,0)

- `metrics_list`: matriz de métricas individuais com:
 - `name`: identificador de métricas (por exemplo, “precisão”, “fluência”)
 - `value`: pontuação de métricas (normalmente de 0,0 a 1,0)
 - `type`: “métrica” (para relatórios) ou “recompensa” (usada no treinamento)

permissões do IAM

Permissões obrigatórias

O perfil de execução do SageMaker AI precisa de permissões para invocar sua função do Lambda. Anexe esta política ao seu perfil de execução do SageMaker AI:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "lambda:InvokeFunction"
      ],
      "Resource": "arn:aws:lambda:region:account-id:function:function-name"
    }
  ]
}
```

Função de execução do Lambda

O perfil de execução de uma função do Lambda precisa de permissões básicas de execução do Lambda:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "logs:CreateLogGroup",
        "logs:CreateLogStream",
        "logs:PutLogEvents"
      ],
    }
  ]
}
```

```
    "Resource": "arn:aws:logs:*:*:*"
  }
]
}
```

Permissões adicionais: se sua função do Lambda acessar outros serviços da AWS (por exemplo, Amazon S3 para dados de referência, DynamoDB para registro em log), adicione essas permissões ao perfil de execução do Lambda.

Execução da tarefa de avaliação

1. Preparar seus dados

- Formate seus dados de avaliação de acordo com os requisitos de formato de dados
- Faça upload de seu arquivo JSONL no Amazon S3: `s3://your-bucket/eval-data/eval_data.jsonl`

2. Configurar sua fórmula

Atualize a fórmula do exemplo com sua configuração:

- Defina `model_name_or_path` para a localização do seu modelo
- Defina `lambda_arn` para o ARN da função de recompensa
- Defina `output_s3_path` para o local de saída desejado
- Ajuste os parâmetros `inference` conforme necessário

Salve a fórmula como `rft_eval_recipe.yaml`

3. Executar a avaliação

Execute a tarefa de avaliação usando o caderno fornecido: [caderno de avaliação do modelo Nova](#)

4. Monitore o progresso

Monitore sua tarefa de avaliação por meio do:

- Console do SageMaker AI: verifique o status e os logs da tarefa
- CloudWatch Logs: visualize logs de execução detalhados
- Lambda Logs: depure problemas na função de recompensa

Conceitos básicos dos resultados da avaliação

Formato de saída

A tarefa de avaliação gera resultados para a localização específica do Amazon S3 no formato JSONL. Cada linha contém os resultados da avaliação de um exemplo:

```
{
  "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

A saída da tarefa de avaliação de RFT é idêntica ao formato da resposta do Lambda. O serviço de avaliação passa pela resposta da função do Lambda sem modificação, garantindo a consistência entre seus cálculos de recompensa e os resultados finais.

Como interpretar os resultados do

Pontuação de recompensa agregada:

- Intervalo: normalmente de 0,0 (pior) a 1,0 (melhor), mas depende da sua implementação
- Objetivo: número único resumindo o desempenho geral
- Uso: compare modelos, acompanhe a melhoria em relação ao treinamento

Métricas individuais:

- Tipo de métrica: métricas informativas para análise
- Tipo de recompensa: métricas usadas durante o treinamento de RFT
- Interpretação: valores mais altos geralmente indicam melhor desempenho (a menos que você crie métricas inversas)

Benchmarks de desempenho

O que constitui um desempenho “bom” depende do seu caso de uso:

Intervalo de pontuação	Interpretação	Ação
0,8 a 1,0	Excelente	Modelo pronto para implantação
0,6 a 0,8	Boa	Pequenas melhorias podem ser benéficas
0,4 a 0,6	Razoável	Melhoria significativa necessária
0,0 a 0,4	Ruim	Revise os dados de treinamento e a função de recompensa

Important

Essas são as diretrizes gerais. Defina seus próprios limites com base nos requisitos de negócios, no desempenho do modelo de base, nas restrições específicas do domínio e na análise de custo-benefício do treinamento adicional.

Monitoramento das tarefas do HyperPod com o MLflow

Você pode usar o MLflow para rastrear e monitorar suas tarefas de treinamento no SageMaker HyperPod. Siga estas etapas para configurar o MLflow e conectá-lo às suas fórmulas de treinamento.

Crie o aplicativo MLflow

Exemplo de comando da AWS CLI

```
aws sagemaker-mlflow create-mlflow-app \  
  --name <app-name> \  
  --artifact-store-uri <s3-bucket-name> \  
  --role-arn <role-arn> \  
  --region <region-name>
```

Exemplo de saída

```
{  
  "Arn": "arn:aws:sagemaker:us-east-1:111122223333:mlflow-app/app-LGZE0Z2UY4NZ"  
}
```

Gere um URL pré-assinado

Exemplo de comando da AWS CLI

```
aws sagemaker-mlflow create-presigned-mlflow-app-url \  
  --arn <app-arn> \  
  --region <region-name> \  
  --output text
```

Exemplo de saída


```
https://app-LGZE0Z2UY4NZ.mlflow.sagemaker.us-east-1.app.aws/auth?  
authToken=eyJhbGciOiJIUzI1NiJ9.eyJhdXRoVG9rZW5JZCI6IkxETVBPUyIsImZhc0NyZWRLbnRpYWxzIjoiQWdWNGhD
```

Abra o URL pré-assinado e visualize a aplicação

Clique em

```
https://app-LGZE0Z2UY4NZ.mlflow.sagemaker.us-east-1.app.aws/auth?  
authToken=eyJhbGciOiJIUzI1NiJ9.eyJhdXRoVG9rZW5JZCI6IkxETVBPUyIsImZhc0NyZWRLbnRpYWxzIjoiQWdWNGhD
```

Visualizar




Passe para a fórmula no bloco de execução da sua fórmula do SageMaker HyperPod

Fórmula

```
run
  mlflow_tracking_uri: arn:aws:sagemaker:us-east-1:111122223333:mlflow-app/app-
  LGZE0Z2UY4NZ
```

Visualizar



Treinamento iterativo

Visão geral

O treinamento iterativo é o processo de ajustar repetidamente um modelo por meio de vários ciclos de treinamento em diferentes métodos de treinamento (treinar, avaliar, analisar erros, ajustar dados/objetivos/hiperparâmetros), com cada rodada começando no ponto de verificação anterior. Essa abordagem permite direcionar sistematicamente os modos de falha do modelo, incorporar exemplos selecionados que abordam pontos fracos específicos e se adaptar às mudanças nos requisitos ao longo do tempo.

Benefícios em relação ao treinamento de etapa única:

- Melhoria direcionada: analise padrões de falha específicos descobertos por meio da avaliação
- Refinamento adaptativo: responda às mudanças de distribuição ou à evolução dos requisitos do produto
- Mitigação de riscos: valide as melhorias de forma incremental em vez de se comprometer com uma única execução de treinamento longo
- Eficiência de dados: concentre os esforços de coleta de dados nas áreas em que o modelo tem uma performance inferior
- Treinamento curricular: várias rodadas de treinamento com dados de qualidade progressivamente superior

Como funciona

Acesso e local do ponto de verificação

Após a conclusão de cada tarefa de treinamento, um arquivo manifesto é gerado no local de saída especificado pelo parâmetro `output_path` em sua configuração de treinamento.

Para acessar seu ponto de verificação

- Navegue até o `output_path` especificado no S3
- Faça o download e extraia o arquivo `output.tar.gz`.
- Abra o arquivo `manifest.json` que está dentro
- Localize o parâmetro `checkpoint_s3_bucket`, que contém o URI do S3 do seu modelo treinado

Exemplo de estrutura `manifest.json`

```
{
  "checkpoint_s3_bucket": "s3://customer-escrow-<account-number>-smtj-<unique-
  identifier>/<job-name>/stepID",
  ...
}
```

Noções básicas sobre buckets de depósito

Como os pesos do Amazon Nova são proprietários, os pontos de verificação de modelos treinados são armazenados em buckets de depósito do S3 em contas gerenciadas pela AWS, em vez de serem copiados para sua conta. Esses buckets de depósito:

- Contêm seus pesos de modelos personalizados com segurança
- Podem ser referenciados por outros serviços da AWS (inferência, avaliação e trabalhos de treinamento subsequentes)
- São acessíveis somente pela sua conta da AWS por meio de permissões do IAM
- Incorrem em cobranças de armazenamento padrão do S3 em sua conta (consulte Considerações sobre custo)

Você pode usar o caminho do bucket de depósito como `model_name_or_path` em sua próxima execução de treinamento para continuar o treinamento iterativo.

Uso de pontos de verificação para treinamento iterativo

Configure sua próxima tarefa de treinamento para usar o ponto de verificação anterior como modelo de 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 usar o treinamento iterativo

Casos de uso ideais

Use o treinamento iterativo quando você tiver:

- Ciclos de comentários: capacidade para coletar casos de falha do mundo real e analisá-los sistematicamente
- Ambientes dinâmicos: documentação em evolução, APIs ou tópicos de suporte que exigem atualizações periódicas do modelo
- Avaliação robusta: avaliações comparativas e frameworks de avaliação fortes (veja os exemplos abaixo) para avaliar as melhorias com confiança
- Capacidade de operações de ML: recursos para gerenciar vários ciclos de treinamento e controle de versão

Exemplos de frameworks robustos de avaliação

- Conjuntos de avaliações comparativas automatizadas com limites de aprovação/reprovação
- Protocolos de avaliação humana com métricas de confiabilidade entre avaliadores
- Cenários de testes da red-team que abrangem casos de borda e entradas adversariais
- Infraestrutura de testes A/B para avaliar o impacto na produção

Padrões comuns

SFT → Pipeline do RFT: um padrão iterativo usado com frequência envolve:

- SFT primeiro: ensine o modelo a resolver problemas por meio de exemplos de demonstração
- RFT segundo: otimize a performance em todo o espaço de problemas usando sinais de recompensa

Essa sequência é essencial quando os modelos têm uma performance inicial ruim. O RFT em modelos de precisão próxima de zero não melhorará a performance sem primeiro estabelecer recursos básicos de resolução de problemas por meio do SFT.

Quando não usar o treinamento iterativo

Evite o treinamento iterativo para:

- Tarefas estáveis e bem definidas: dados estacionários com requisitos consistentes que já atingem uma performance próxima ao limite máximo
- Problemas simples de classificação: tarefas restritas em que o treinamento de uma única etapa é suficiente
- Restrições de recursos: falta de recursos operacionais de ML dedicados para gerenciar vários ciclos de treinamento
- Ganhos marginais: quando a sobrecarga não justifica melhorias mínimas de performance

Exemplo de fluxo de trabalho: SFT → RFT

Este exemplo demonstra um padrão comum de treinamento iterativo para modelos de raciocínio.

Etapa 1: treinamento inicial do SFT

Configure e inicie sua tarefa de treinamento de SFT com seu conjunto de dados:

```
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
```

Justificativa: o SFT fornece demonstrações adicionais que moldam as saídas do modelo no formato e na voz desejados, estabelecendo recursos fundamentais.

Após o treinamento ser concluído

- Observe o `output_path` configurado em sua tarefa de treinamento
- Faça o download de `output.tar.gz` nesse local
- Extraia e localize `manifest.json`
- Copie o valor `checkpoint_s3_bucket`

Etapa 2: treinamento de RFT no ponto de verificação do SFT

Crie uma nova tarefa de treinamento de RFT usando o ponto de verificação do 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>
```

Justificativa: o treinamento de RFT se baseia nos fundamentos do SFT, permitindo que o modelo desenvolva padrões de raciocínio mais complexos, otimizados por sua função de recompensa.

Etapa 3: avaliar e iterar

Execute a avaliação no ponto de verificação do RFT para avaliar a performance:

```
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 as métricas-alvo não forem satisfeitas, continue iterando com dados ou hiperparâmetros ajustados.

Important

A técnica de treinamento (LoRA versus full-rank) deve permanecer consistente em todas as iterações:

- Se você usa o SFT com LoRA, deve usar o RFT com LoRA
- Se você usa o SFT com full-rank, deve usar o RFT com full-rank
- Você não pode alternar entre LoRA e full-rank no meio do pipeline

Important

Se uma chave do KMS for usada para criptografia no bucket de saída do S3 de propriedade da Amazon, essa mesma chave do KMS deverá ser usada para todas as iterações futuras.

Monitoramento do progresso em todas as iterações

Você pode monitorar as métricas por meio do MLflow [configurando o MLflow](#) em suas tarefas.

Criar uma aplicação MLflow

Usando a interface do usuário do Studio: se você criar uma tarefa de treinamento por meio da interface do usuário do Studio, uma aplicação MLflow padrão será criada automaticamente e estará selecionada por padrão em Opções avançadas.

Usando a CLI: se você usar a CLI, deverá criar uma aplicação MLflow e passá-la como uma entrada para a solicitação da API da tarefa de treinamento.

```
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)
```

Acessar a aplicação MLflow

Usando a CLI: crie um URL pré-assinado para acessar a interface do usuário da aplicação MLflow:

```
aws sagemaker create-presigned-mlflow-app-url \
  --arn $mlflow_app_arn \
  --region $region \
  --output text
```

Usando a interface do usuário do Studio: a interface do usuário do Studio exibe as principais métricas armazenadas no MLflow e fornece um link para a interface do usuário da aplicação MLflow.

Principais métricas a serem acompanhadas

Monitore essas métricas em todas as iterações para avaliar a melhoria e acompanhar o progresso da tarefa:

No SFT

- Curvas de perda de treinamento
- Número de amostras consumidas e tempo para processar amostras
- Precisão de performance em conjuntos de teste retidos
- Conformidade de formato (por exemplo, taxa de saída JSON válida)
- Perplexidade nos dados de avaliação específicos do domínio

No RFT

- Pontuações médias de recompensa em relação ao treinamento

- Distribuição de recompensas (porcentagem de respostas de alta recompensa)
- Tendências de recompensa de validação (observe se há sobreajuste)
- Taxas de sucesso específicas de tarefas (por exemplo, taxa de aprovação de execução de código, precisão de problemas matemáticos)

Geral

- Avaliação comparativa dos deltas de performance entre as iterações
- Pontuações de avaliação humana em amostras representativas
- Métricas de produção (se implantadas de forma iterativa)

Determinação de quando parar

Pare de iterar quando:

- Estagnação da performance: o treinamento adicional não melhora mais significativamente as métricas-alvo
- Trocar de técnica ajuda: se uma técnica estagnar, tente alternar (por exemplo, SFT → RFT → SFT) para ultrapassar os limites de performance
- Métricas-alvo alcançadas: seus critérios de sucesso foram atendidos
- Regressão detectada: novas iterações degradam a performance (consulte os procedimentos de reversão abaixo)

Para obter procedimentos de avaliação detalhados, consulte a seção Avaliação.

Práticas recomendadas

Comece pequeno e escale gradualmente

Comece com conjuntos de dados mínimos e épocas únicas de treinamento para validar sua abordagem antes de aumentar a escala verticalmente. Isso aumenta a confiança e ajuda a identificar problemas de forma antecipada.

Estabelecer métricas de sucesso claras

Defina indicadores quantitativos e qualitativos antes de começar:

Exemplo de métricas de sucesso por caso de uso

- Resposta às perguntas: precisão exata de correspondência, pontuação F1, classificações de preferência humana
- Geração de código: taxa de aprovação no teste unitário, sucesso da compilação, tempo de execução
- Tarefas de raciocínio: precisão das etapas, exatidão das respostas finais, pontuações de recompensa
- Geração de conteúdo: pontuações de coerência, precisão factual, aderência ao estilo

Implementar avaliação automatizada

Configure pipelines de avaliação automatizados para monitorar a performance após cada rodada, permitindo uma rápida iteração e comparação objetiva.

Manter um controle de versão rigoroso

Documento para cada iteração:

- Versões e modificações do conjunto de dados
- Locais dos pontos de verificação do modelo
- Alterações de hiperparâmetros
- Deltas e métricas de performance
- Observações qualitativas

Isso cria conhecimento institucional e permite a depuração.

Concentrar-se na qualidade dos dados em vez da quantidade

Analise casos de falha de rodadas anteriores e adicione exemplos direcionados e de alta qualidade em vez de simplesmente aumentar o tamanho do conjunto de dados.

Planejar o orçamento de iteração

Planeje de 3 a 5 iterações como um intervalo típico:

- 1 a 2 iterações: geralmente são suficientes para melhorias simples ou polimento final

- 3 a 5 iterações: adequado para tarefas complexas que exigem vários ciclos de refinamento
- Mais de 5 iterações: pode indicar retornos decrescentes ou necessidade de abordagens diferentes

Ajuste com base no orçamento computacional e nas taxas de melhoria de performance.

Implementar recursos de reversão

Se uma iteração introduzir regressões:

- Identifique a regressão: compare as métricas de avaliação em todos os pontos de verificação
- Retorne ao ponto de verificação anterior: use o caminho do S3 do ponto de verificação anterior como seu `model_name_or_path`
- Ajuste a abordagem de treinamento: modifique dados, hiperparâmetros ou técnicas antes de tentar novamente
- Documente a falha: registre o que causou a regressão para evitar que se repita

Exemplo de reversão

```
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>"
```

Considerações sobre custos

Armazenamento de pontos de verificação

- Local: os pontos de verificação armazenados em buckets de depósito incorrem em cobranças padrão de armazenamento do S3 faturadas em sua conta da AWS
- Retenção: os pontos de verificação são retidos indefinidamente, a menos que sejam explicitamente excluídos
- Gerenciamento: implemente políticas de ciclo de vida para arquivar ou excluir pontos de verificação antigos de que você não precisa mais

Dicas de otimização de custos

- Exclua os pontos de verificação intermediários após validar as iterações mais recentes
- Arquive pontos de verificação no S3 Glacier para retenção de longo prazo a um custo menor
- Defina políticas de retenção com base em suas necessidades de conformidade e experimentação

Limitações

Consistência da família de modelos

Ao treinar iterativamente, você deve usar o mesmo tipo de modelo em todas as iterações.

Treinamento inicial

```
run:
  model_type: amazon.nova-2-lite-v1:0:256k
  model_name_or_path: "nova-lite-2/prod"
```

As iterações subsequentes devem usar o mesmo `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>"
```

Consistência da técnica de treinamento

A técnica de treinamento deve permanecer consistente em todas as iterações:

- Modelos treinados via LoRA só podem ser treinados iterativamente via LoRA
- Modelos treinados em full-rank só podem ser treinados de forma iterativa em full-rank

Como os adaptadores LoRA funcionam no treinamento iterativo

- Cada iteração de treinamento LoRA gera novos pesos de adaptador
- Os novos adaptadores substituem (não se empilham) os adaptadores anteriores
- O modelo de base permanece congelado; somente os adaptadores são atualizados

Matriz de compatibilidade de técnicas

Treinamento inicial	Pode iterar com
SFT (full-rank)	SFT (full-rank), RFT (full-rank)
SFT (LoRA)	SFT (LoRA), RFT (LoRA)
RFT (full-rank)	RFT (full-rank)
RFT (LoRA)	RFT (LoRA)

Verificação da compatibilidade antes de iniciar uma tarefa

- Verifique sua fórmula de treinamento anterior para identificar o tipo de modelo e a técnica de treinamento (LoRA vs. full-rank)
- Certifique-se de que sua nova fórmula corresponda ao tipo de modelo e à técnica
- Revise o manifest.json para confirmar se o caminho do ponto de verificação está correto

Solução de problemas

Erro: “Incompatible model training techniques detected”

Causa: a técnica de treinamento (LoRA vs. full-rank) não corresponde à técnica do ponto de verificação.

Resolução: certifique-se de que sua fórmula use a mesma técnica de treinamento do modelo original:

- Se o ponto de verificação tiver sido treinado com LoRA, use a LoRA em sua nova fórmula
- Se o checkpoint foi treinado com full-rank, use-o em sua nova fórmula

Erro: “Base model for the job extracted from model_name_or_path does not match model_type”

Causa: o tipo de modelo especificado em `model_type` não corresponde ao modelo real no ponto de verificação.

Resolução: verifique se:

- O `model_type` em sua fórmula corresponde ao tipo do modelo original
- O caminho do ponto de verificação do S3 em `model_name_or_path` está correto
- Você está usando o caminho do arquivo `manifest.json` correto

Exemplo de configuração correta

```
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>"
```

Erro: “Model configuration not found”

Causa: o caminho do S3 em `model_name_or_path` é inválido ou está inacessível.

Resolução:

- Verifique se o caminho do S3 foi copiado corretamente do arquivo `manifest.json`
- Garanta que seu perfil do IAM tenha permissões para acessar o bucket de depósito
- Confirme se a tarefa de treinamento anterior foi concluída com êxito
- Verifique se há erros de digitação no caminho

Regressão da performance após a iteração

Sintomas: as métricas de avaliação diminuem após uma nova iteração de treinamento.

Resolução:

- Reverter: use o ponto de verificação anterior como seu modelo de base
- Analisar: revise os logs de treinamento e a qualidade dos dados da iteração que falhou
- Ajustar: modifique os hiperparâmetros (reduza a taxa de aprendizado), melhore a qualidade dos dados ou reduza as épocas de treinamento
- Tentar novamente: inicie uma nova iteração com ajustes

Interface do SageMaker

Os modelos personalizados do Amazon Nova agora estão disponíveis na inferência do SageMaker. Com o Amazon Nova no SageMaker, você pode começar a obter previsões ou inferências dos modelos treinados personalizados do Amazon Nova. O SageMaker oferece uma ampla seleção de infraestrutura de machine learning e opções de implantação de modelos para ajudar a atender a todas as suas necessidades de inferência de ML. Com a inferência do SageMaker, você pode escalar a implantação de modelos, gerenciar os modelos em produção de forma mais eficaz e reduzir a carga operacional.

O SageMaker fornece várias opções de inferência, como endpoints em tempo real para obter inferência de baixa latência e endpoints assíncronos para lotes de solicitações. Ao utilizar a opção de inferência apropriada para o caso de uso, você pode garantir a eficiência da implantação e inferência do modelo. Para obter mais informações sobre a inferência do SageMaker, consulte [Implantar modelos para inferência](#).

Important

Somente modelos personalizados full-rank e modelos mesclados com LoRA são compatíveis com a inferência do SageMaker. Para modelos LoRA e modelos de base não mesclados, use o Amazon Bedrock.

Recursos

Os seguintes recursos estão disponíveis para modelos do Amazon Nova na inferência do SageMaker:

Recursos dos modelos

- Geração de texto

Implantação e escalabilidade

- Endpoints em tempo real com seleção de instância personalizada
- Ajuste de escala automático: ajuste automaticamente a capacidade com base nos padrões de tráfego para otimizar os custos e a utilização da GPU. Para obter mais informações, consulte [Ajuste de escala automático de modelos do Amazon SageMaker](#).

- Suporte à API de streaming para geração de tokens em tempo real

Monitoramento e otimização

- Integração do Amazon CloudWatch para monitoramento e alertas
- Otimização de latência com reconhecimento de zonas de disponibilidade por meio da configuração de VPC

ferramentas de desenvolvimento da

- Suporte da AWS CLI: para obter mais informações, consulte [Referência de comandos da AWS CLI para o SageMaker](#).
- Integração de cadernos via suporte do SDK

Modelos e instâncias compatíveis

Ao criar seus endpoints de inferência do SageMaker, você pode definir duas variáveis de ambiente para configurar sua implantação: `CONTEXT_LENGTH` e `MAX_CONCURRENCY`.

- `CONTEXT_LENGTH`: tamanho máximo total do token (entrada + saída) por solicitação
- `MAX_CONCURRENCY`: número máximo de solicitações simultâneas atendidas pelo endpoint

A tabela a seguir lista os modelos compatíveis do Amazon Nova, os tipos de instâncias e as configurações compatíveis. Os valores de `MAX_CONCURRENCY` representam a simultaneidade máxima suportada para cada configuração `CONTEXT_LENGTH`:

Modelo	Tipo de instância	Configurações compatíveis
Amazon Nova Micro	ml.g5.12xlarge	<code>CONTEXT_LENGTH</code> : 4000, <code>MAX_CONCURRENCY</code> : 32
		<code>CONTEXT_LENGTH</code> : 8000, <code>MAX_CONCURRENCY</code> : 16
	ml.g5.24xlarge	<code>CONTEXT_LENGTH</code> : 8000, <code>MAX_CONCURRENCY</code> : 32

Modelo	Tipo de instância	Configurações compatíveis
	ml.g6.12xlarge	CONTEXT_LENGTH: 4000, MAX_CONCURRENCY: 32
		CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 16
	ml.g6.24xlarge	CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 32
	ml.g6.48xlarge	CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 32
	ml.p5.48xlarge	CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 32
		CONTEXT_LENGTH: 16000, MAX_CONCURRENCY: 2
Amazon Nova Lite		CONTEXT_LENGTH: 24000, MAX_CONCURRENCY: 1
	ml.g6.48xlarge	CONTEXT_LENGTH: 4000, MAX_CONCURRENCY: 32
		CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 16
		CONTEXT_LENGTH: 16000, MAX_CONCURRENCY: 2
	ml.p5.48xlarge	CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 32
		CONTEXT_LENGTH: 16000, MAX_CONCURRENCY: 2
		CONTEXT_LENGTH: 24000, MAX_CONCURRENCY: 1

Modelo	Tipo de instância	Configurações compatíveis
Nova 2 Lite	ml.p5.48xlarge	CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 32 CONTEXT_LENGTH: 16000, MAX_CONCURRENCY: 2 CONTEXT_LENGTH: 24000, MAX_CONCURRENCY: 1

Note

Os valores de MAX_CONCURRENCY mostrados são limites máximos para cada configuração CONTEXT_LENGTH. Você pode usar tamanhos de contexto menores com a mesma simultaneidade, mas exceder esses valores fará com que a criação do endpoint do SageMaker falhe.

Por exemplo, no Amazon Nova Micro com ml.g5.12xlarge:

- CONTEXT_LENGTH=2000, MAX_CONCURRENCY=32 → Válido
- CONTEXT_LENGTH=8000, MAX_CONCURRENCY=32 → Rejeitado (o limite de simultaneidade é 16 no tamanho de contexto 8000)
- CONTEXT_LENGTH=8000, MAX_CONCURRENCY=4 → Válido
- CONTEXT_LENGTH=8000, MAX_CONCURRENCY=16 → Válido
- CONTEXT_LENGTH=10000 → Rejeitado (a extensão máxima do contexto é 8.000 nesta instância)

Regiões do AWS compatíveis

A tabela abaixo lista as regiões da AWS em que os modelos do Amazon Nova estão disponíveis na inferência do SageMaker:

Nome da Região	Código da região	Disponibilidade
Leste dos EUA (Norte da Virgínia)	us-east-1	Available (Disponível)

Nome da Região	Código da região	Disponibilidade
Oeste dos EUA (Oregon)	us-west-2	Available (Disponível)

Imagens de contêineres compatíveis

A tabela a seguir lista os URIs de imagens de contêineres para modelos do Amazon Nova na inferência do SageMaker por região. Duas tags de imagem estão disponíveis para cada região: uma tag versionada (v1.0.0) e uma tag mais recente (SM-Inference-latest). Para implantações de produção, recomendamos usar a tag versionada.

Região	URIs das imagens de contêineres
us-east-1	708977205387.dkr.ecr.us-east-1.amazonaws.com/ nova-inference-repo:SM-Inference-latest
us-west-2	176779409107.dkr.ecr.us-west-2.amazonaws.com/ nova-inference-repo:SM-Inference-latest

Práticas recomendadas

Para verificar as práticas recomendadas de implantação e gerenciamento de modelos no SageMaker, consulte [Práticas recomendadas do SageMaker](#).

Suporte

Para obter suporte e resolver problemas com os modelos do Amazon Nova na inferência do SageMaker, entre em contato com o AWS Support pelo console ou seu gerente de conta da AWS.

Tópicos

- [Conceitos básicos](#)
- [Referência da API](#)
- [Avaliar modelos hospedados na inferência do SageMaker](#)
- [Implantação de modelos do Amazon Nova Forge na detecção de abusos da Inferência do Amazon SageMaker](#)

Conceitos básicos

Este guia mostra como implantar modelos personalizados do Amazon Nova nos endpoints em tempo real do SageMaker, configurar parâmetros de inferência e invocar seus modelos para testes.

Pré-requisitos

Confira abaixo os pré-requisitos para implantar modelos do Amazon Nova na inferência do SageMaker:

- Crie uma Conta da AWS: se você ainda não tiver uma, consulte [Criar uma conta da AWS](#).
- Permissões necessárias do IAM - certifique-se de que seu usuário ou perfil do IAM tenha as seguintes políticas gerenciadas:
 - AmazonSageMakerFullAccess
 - AmazonS3FullAccess
- Versões obrigatórias de SDKs/CLI - as seguintes versões de SDK foram testadas e validadas com modelos do Amazon Nova na inferência do SageMaker:
 - SageMaker Python SDK v3.0.0+ (`sagemaker>=3.0.0`) para abordagem de API baseada em recursos.
 - Boto3 versão 1.35.0+ (`boto3>=1.35.0`) para chamadas diretas de API. Os exemplos neste guia usam essa abordagem.
- Aumento da cota de serviço: solicite um aumento da cota de serviço do Amazon SageMaker para o tipo de instância de ML que você planeja usar para seu endpoint da Inferência do SageMaker (por exemplo, `m1.p5.48xlarge` for `endpoint usage`). Para obter uma lista dos tipos de instâncias compatíveis, consulte [the section called “Modelos e instâncias compatíveis”](#). Para solicitar um aumento, consulte [Solicitar um aumento de cota](#). Para obter mais informações sobre cotas de instâncias do SageMaker, consulte [Endpoints e cotas do SageMaker](#).

Etapa 1: configurar as credenciais da AWS

Configure suas credenciais da AWS usando um dos seguintes métodos:

Opção 1: AWS CLI (recomendado)

```
aws configure
```

Insira o ID da chave de acesso da AWS, a chave secreta e nome da região padrão quando solicitado.

Opção 2: arquivo de credenciais da AWS

Crie ou edite ~/.aws/credentials:

```
[default]
aws_access_key_id = YOUR_ACCESS_KEY
aws_secret_access_key = YOUR_SECRET_KEY
```

Opção 3: variáveis de ambiente

```
export AWS_ACCESS_KEY_ID=your_access_key
export AWS_SECRET_ACCESS_KEY=your_secret_key
```

Note

Para obter mais informações sobre as credenciais da AWS, consulte [Definições do arquivo de credenciais e configurações](#).

Inicializar clientes da AWS

Crie um script ou caderno Python com o código abaixo para inicializar o AWS SDK e verificar suas credenciais:

```
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 a autenticação tiver êxito, você deverá ver um resultado confirmando o ID da sua conta da AWS.

Etapa 2: criar um perfil de execução do SageMaker

Um perfil de execução do SageMaker é um perfil do IAM que concede ao SageMaker permissões para acessar recursos da AWS em seu nome, como buckets do Amazon S3 para artefatos de modelos e o CloudWatch para registro em log.

Criação do perfil de execução

Note

A criação de perfis do IAM requer as permissões `iam:CreateRole` e `iam:AttachRolePolicy`. Antes de continuar, certifique-se de que seu usuário ou perfil do IAM tenha essas permissões.

O código abaixo cria um perfil do IAM com as permissões necessárias para implantar modelos personalizados do 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}")

```

Uso de um perfil de execução existente (opcional)

Se já tiver um perfil de execução do SageMaker, você poderá usá-lo:

```

# Replace with your existing role ARN
SAGEMAKER_EXECUTION_ROLE_ARN = "arn:aws:iam::YOUR_ACCOUNT_ID:role/
YOUR_EXISTING_ROLE_NAME"

```

Para encontrar perfis existentes do SageMaker em sua conta:

```

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

O perfil de execução deve ter uma relação de confiança com `sagemaker.amazonaws.com` e permissões para acessar os recursos do Amazon S3 e do SageMaker.

Para obter mais informações sobre perfis de execução do SageMaker, consulte [Perfis do SageMaker](#).

Etapa 3: configurar parâmetros de modelos

Configure os parâmetros de implantação para seu modelo do Amazon Nova. Essas configurações controlam o comportamento do modelo, a alocação de recursos e as características de inferência. Para ver uma lista dos tipos de instâncias compatíveis e dos valores de `CONTEXT_LENGTH` e `MAX_CONCURRENCY` compatíveis para cada um, consulte [the section called “Modelos e instâncias compatíveis”](#).

Parâmetros obrigatórios

- `IMAGE`: o URI da imagem do contêiner do Docker para o contêiner de inferência do Amazon Nova. Será fornecido pela AWS.
- `CONTEXT_LENGTH`: tamanho do contexto do modelo.
- `MAX_CONCURRENCY`: número máximo de sequências por iteração; define o limite de quantas solicitações (prompts) de usuários individuais podem ser processadas simultaneamente em um único lote na GPU. Intervalo: inteiro maior que 0.

Parâmetros opcionais de geração

- `DEFAULT_TEMPERATURE`: controla a randomização na geração. Intervalo: de 0,0 a 2,0 (0,0 = determinístico, maior = mais randomizado).
- `DEFAULT_TOP_P`: limite de amostragem de núcleo para a seleção de tokens. Intervalo: de 1e-10 a 1,0.
- `DEFAULT_TOP_K`: limita a seleção de tokens aos K tokens mais prováveis. Intervalo: inteiro -1 ou maior (-1 = sem limite).
- `DEFAULT_MAX_NEW_TOKENS`: número máximo de tokens a serem gerados na resposta (ou seja, máximo de tokens de saída). Intervalo: inteiro 1 ou maior.

- **DEFAULT_LOGPROBS:** número de probabilidades logarítmicas a serem retornadas por token.
Intervalo: inteiro de 1 a 20.

Configure sua implantação

```
# 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}")

```

Configurar parâmetros específicos da implantação

Agora configure os parâmetros específicos para a implantação de modelos do Amazon Nova, incluindo o local dos artefatos do modelo e a seleção do tipo de instância.

Definir identificador de implantação

```

# Deployment identifier - use a descriptive name for your use case
JOB_NAME = "my-nova-deployment"

```

Especificar o local dos artefatos dos modelos

Forneça o URI do Amazon S3 em que os artefatos treinados dos modelos do Amazon Nova foram armazenados. Deve ser o local da saída da tarefa de treinamento de modelo ou de ajuste fino.

```

# 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/"

```

Selecionar a variante do modelo e o tipo de instância

```

# 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}")
```

Convenções de nomenclatura

O código gera automaticamente nomes consistentes para os recursos da AWS:

- Nome do modelo: `:: {JOB_NAME}-{model}-{instance-type}`
- Configuração de endpoint: `{MODEL_NAME}-Config`
- Nome do endpoint: `{MODEL_NAME}-Endpoint`

Etapa 4: criar a configuração do modelo e endpoint do SageMaker

Nesta etapa, você criará dois recursos essenciais: um objeto de modelo do SageMaker que faz referência aos artefatos dos modelos do Amazon Nova e uma configuração do endpoint que define como o modelo será implantado.

Modelo do SageMaker: um objeto de modelo que empacota a imagem do contêiner de inferência, o local dos artefatos do modelo e a configuração do ambiente. Este é um recurso reutilizável que pode ser implantado em vários endpoints.

Configuração do endpoint: define as configurações de infraestrutura para implantação, incluindo tipo de instância, contagem de instâncias e variantes do modelo. Isso permite que você gerencie as configurações de implantação separadamente do próprio modelo.

Criar o modelo do SageMaker

O código abaixo cria um modelo do SageMaker que faz referência aos artefatos do seu modelo do 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}")

```

Principais parâmetros:

- **ModelName**: identificador exclusivo do seu modelo
- **Image**: URI de imagem de contêiner do Docker para inferência do Amazon Nova
- **ModelDataSource**: local do Amazon S3 dos seus artefatos de modelos
- **Environment**: variáveis de ambiente configuradas na Etapa 3
- **ExecutionRoleArn**: perfil do IAM da Etapa 2
- **EnableNetworkIsolation**: defina como True para aumentar a segurança (impede que o contêiner faça chamadas de rede de saída)

Criar a configuração do endpoint

Em seguida, crie uma configuração do endpoint que defina sua infraestrutura de implantação:

```

# 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}")
```

Principais parâmetros:

- **VariantName**: identificador para essa variante de modelo (use “primary” para implantações de modelo único)
- **ModelName**: faz referência ao modelo criado acima
- **InitialInstanceCount**: número de instâncias a serem implantadas (comece com 1 e escale posteriormente, se necessário)
- **InstanceType**: tipo de instância de ML selecionado na Etapa 3

Verificar a criação de recursos

Você pode verificar se os recursos foram criados com êxito:

```
# 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")
```

Etapa 5: implantar o endpoint

A próxima etapa é implantar seu modelo do Amazon Nova criando um endpoint em tempo real do SageMaker. Esse endpoint hospedará seu modelo e fornecerá um endpoint HTTPS seguro para fazer solicitações de inferência.

A criação do endpoint normalmente leva de 15 a 30 minutos, pois a AWS provisiona a infraestrutura, faz o download dos artefatos do modelo e inicializa o contêiner de inferência.

Criar o 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}")
```

Monitorar a criação do endpoint

O código abaixo pesquisa o status do endpoint até a conclusão da implantação:

```
# 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

```

Verificar se o endpoint está pronto

Quando o endpoint estiver InService, você poderá verificar sua configuração:

```

# 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

```

Solução de problemas de falhas na criação de endpoints

Motivos de falha comuns:

- Capacidade insuficiente: o tipo de instância solicitada não está disponível na sua região.

- Solução: tente um tipo de instância diferente ou solicite um aumento da cota
- Permissões do IAM: o perfil de execução não tem as permissões necessárias
 - Solução: verifique se o perfil tem acesso aos artefatos dos modelos do Amazon S3 e às permissões necessárias do SageMaker
- Artefatos do modelo não encontrados: o URI do Amazon S3 está incorreto ou inacessível
 - Solução: verifique o URI do Amazon S3, as permissões do bucket e se você está na região correta
- Limites de recursos: limites da conta excedidos para endpoints ou instâncias
 - Solução: solicite um aumento de cota de serviço por meio do Service Quotas ou do AWS Support

Note

Se você precisar excluir um endpoint com falha e começar de novo:

```
sagemaker.delete_endpoint(EndpointName=ENDPOINT_NAME)
```

Etapa 6: invocar o endpoint

Quando seu endpoint estiver InService, você poderá enviar solicitações de inferência para gerar previsões do seu modelo do Amazon Nova. O SageMaker oferece suporte a endpoints síncronos (em tempo real com os modos de streaming/não streaming) e endpoints assíncronos (baseados no Amazon S3 para processamento em lote).

Configurar o cliente de runtime

Crie um cliente de runtime do SageMaker com as configurações de tempo limite apropriadas:

```
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)

```

Criar uma função de inferência universal

A função abaixo processa solicitações com ou sem 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)}")

```

Exemplo 1: conclusão de chat sem streaming

Use o formato de chat para interações conversacionais:

```

# 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)
```

Resposta de exemplo:

```
{
  "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
  }
}
```

Exemplo 2: conclusão de texto simples

Use o formato de conclusão para geração de texto simples:

```
# 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)
```

Resposta de exemplo:

```
{
  "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
    }
}
```

Exemplo 3: conclusão de chat com 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)
```

Exemplo de saída de 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":"\u25810nce","logprob":-0.6078429222106934,"bytes":
[226,150,129,79,110,99,101],"top_logprobs":
[{"token":"\u25810nce","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]
```

Exemplo 4: conclusão do chat multimodal

Use o formato multimodal para entradas de imagem e texto:

```
# 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)
```

Resposta de exemplo:

```
{  
  "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  
  }  
}
```

Etapa 7: limpar os recursos (opcional)

Para evitar cobranças desnecessárias, exclua os recursos da AWS que você criou durante este tutorial. Os endpoints do SageMaker são cobrados enquanto estão em execução, mesmo que você não esteja ativamente fazendo solicitações de inferência.

Important

A exclusão de recursos é permanente e não poderá ser desfeita. Antes de continuar, certifique-se de que não precisará mais desses recursos.

Excluir o 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

A exclusão do endpoint é assíncrona. Você pode monitorar o status da exclusão:

```
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
```

Excluir a configuração do endpoint

Depois que o endpoint for excluído, remova a configuração dele:

```
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}")
```

Excluir o modelo

Remova o objeto do modelo do SageMaker:

```
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}")
```

Referência da API

Os modelos do Amazon Nova no SageMaker usam a API de execução padrão do SageMaker para inferência. Para verificar a documentação completa da API, consulte [Testar um modelo implantado](#).

Invocação de endpoints

Os modelos do Amazon Nova no SageMaker são compatíveis com dois métodos de invocação:

- Invocação síncrona: use a API [InvokeEndpoint](#) para solicitações de inferência em tempo real e sem streaming.
- Invocação com streaming: use a API [InvokeEndpointWithResponseStream](#) para solicitações de inferência com streaming em tempo real.

Formato de solicitação

Os modelos do Amazon Nova são compatíveis com dois formatos de solicitação:

Formato de conclusão de chat

Use esse formato para interações conversacionais:

```
{
```



```
"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 de conclusão de texto

Use esse formato para geração de texto simples:

```
{
  "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 de conclusão de chat multimodal

Use esse formato para entradas de imagem e texto:

```
{
```

```
"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
}
```

Parâmetros de solicitação

- **messages** (matriz): para formato de conclusão de chat. Matriz de objetos de mensagem com os campos **role** e **content**. O conteúdo pode ser uma string somente para texto ou uma matriz para entradas multimodais.
- **prompt** (string): para formato de conclusão de texto. O texto de entrada para a geração.
- **max_tokens** (inteiro): número máximo de tokens a serem gerados na resposta. Intervalo: 1 ou maior.
- **max_completion_tokens** (inteiro): alternativa a **max_tokens** para conclusões de chats. Número máximo de tokens de conclusão a serem gerados.
- **temperature** (flutuante): controla a randomização na geração. Intervalo: de 0,0 a 2,0 (0,0 = determinístico, 2,0 = randomização máxima).
- **top_p** (flutuante): limite da amostragem do núcleo. Intervalo: de 1e-10 a 1,0.
- **top_k** (inteiro): limita a seleção de tokens aos K tokens mais prováveis. Intervalo: -1 ou maior (-1 = sem limite).
- **stream** (booleano): se a resposta deve ser transmitida. Defina como **true** para streaming, **false** para sem streaming.
- **logprobs** (booleano/inteiro): para conclusões de chat, use booleano. Em conclusões de texto, use um número inteiro para o número de probabilidades logarítmicas a serem retornadas. Intervalo: de 1 a 20.
- **top_logprobs** (inteiro): número de tokens mais prováveis para os quais retornar probabilidades logarítmicas (somente para conclusões de chat).

- **reasoning_effort** (string): nível de esforço de raciocínio. Opções: “baixo”, “alto” (conclusões de bate-papo somente para modelos personalizados do Nova 2 Lite).
- **allowed_token_ids** (matriz): lista de IDs de tokens que podem ser gerados. Restringe a saída aos tokens especificados.
- **truncate_prompt_tokens** (inteiro): trunque o prompt para este número de tokens se ele exceder o limite.
- **stream_options** (objeto): opções para respostas em streaming. Contém o booleano **include_usage** para incluir o uso de tokens nas respostas em streaming.

Formato de resposta

O formato da resposta depende do método de invocação e do tipo de solicitação:

Resposta de conclusão de chat (não streaming)

Para solicitações síncronas de conclusão de 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]
}

```

Resposta de conclusão de texto (não streaming)

Para solicitações síncronas de conclusão de texto:

```

{
  "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
  }
}
}
}

```

Resposta em streaming para conclusão de chat

Para solicitações de conclusão de chat em streaming, as respostas são enviadas como eventos enviados pelo servidor (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
}

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]

```

Resposta em streaming para conclusão de texto

Para solicitações de conclusão de texto em 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]
```

Explicação dos campos de resposta

- **id**: identificador exclusivo para a conclusão
- **object**: tipo de objeto retornado (“chat.completion”, “text_completion”, “chat.completion.chunk”)
- **created**: carimbo de data e hora do Unix de quando a conclusão foi criada
- **model**: modelo usado para a conclusão
- **choices**: matriz de opções de conclusão
- **usage**: informações de uso do token, incluindo prompt, conclusão e total de tokens
- **logprobs**: informações de probabilidade logarítmica para tokens (quando solicitadas)
- **finish_reason**: motivo pelo qual o modelo parou de gerar (“stop”, “length”, “content_filter”)
- **delta**: conteúdo incremental em respostas em streaming
- **reasoning**: conteúdo de raciocínio quando **reasoning_effort** é usado
- **token_ids**: matriz de IDs de tokens para o texto gerado

Para verificar a documentação completa das APIs, consulte a [referência da API InvokeEndpoint](#) e a [referência da API InvokeEndpointWithResponseStream](#).

Avaliar modelos hospedados na inferência do SageMaker

Este guia explica como avaliar seus modelos personalizados do Amazon Nova implantados nos endpoints de inferência do SageMaker usando o [Inspect AI](#), um framework de avaliação de código aberto.

 Note

Para uma explicação prática, consulte o [caderno de início rápido do Inspect A do SageMaker](#).

Visão geral

Você pode avaliar seus modelos personalizados do Amazon Nova implantados nos endpoints do SageMaker usando avaliações comparativas padronizadas da comunidade de pesquisa de IA. Essa abordagem permite que você:

- Avalie modelos personalizados do Amazon Nova (ajustados, destilados ou adaptados de outra forma) em grande escala
- Execute avaliações com inferência paralela em várias instâncias de endpoint
- Compare a performance do modelo usando avaliações comparativas como MMLU, TruthfulQA e HumanEval
- Integre-se à sua infraestrutura existente do SageMaker

Modelos compatíveis

O provedor de inferência do SageMaker trabalha com:

- Modelos do Amazon Nova (Nova Micro, Nova Lite, Nova Lite 2)
- Modelos implantados por meio de servidores de inferência compatíveis com vLLM ou OpenAI
- Qualquer endpoint compatível com o formato da API OpenAI Chat Completions

Pré-requisitos

Antes de começar, verifique se você tem:

- Uma Conta da AWS com permissões para criar e invocar endpoints do SageMaker
- Credenciais da AWS configuradas por meio da AWS CLI, das variáveis de ambiente ou dos perfis do IAM.
- Python 3.9 ou posterior

Permissões obrigatórias do IAM

O usuário ou o perfil do IAM precisa das seguintes permissões:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "sagemaker:InvokeEndpoint",
        "sagemaker:DescribeEndpoint"
      ],
      "Resource": "arn:aws:sagemaker:*:*:endpoint/*"
    }
  ]
}
```

Etapa 1: implantar um endpoint do SageMaker

Antes de executar avaliações, você precisa de um endpoint de inferência do SageMaker executando seu modelo.

Para obter instruções sobre como criar um endpoint de inferência do SageMaker com modelos do Amazon Nova, consulte [the section called “Introdução”](#).

Quando seu endpoint estiver no status InService, anote o nome dele para ser usado nos comandos de avaliação.

Etapa 2: instalar dependências de avaliação

Crie um ambiente virtual Python e instale os pacotes necessários.

```
# Create virtual environment
python3.12 -m venv venv
source venv/bin/activate

# Install uv for faster package installation
pip install uv

# Install Inspect AI and evaluation benchmarks
uv pip install inspect-ai inspect-vals
```

```
# Install AWS dependencies
uv pip install aioboto3 boto3 botocore openai
```

Etapa 3: configurar as credenciais da AWS

Escolha um dos seguintes métodos de autenticação:

Opção 1: AWS CLI (recomendado)

```
aws configure
```

Insira o ID da chave de acesso da AWS, a chave de acesso secreta e a região padrão quando solicitado.

Opção 2: variáveis de ambiente

```
export AWS_ACCESS_KEY_ID=your_access_key
export AWS_SECRET_ACCESS_KEY=your_secret_key
export AWS_DEFAULT_REGION=us-west-2
```

Opção 3: perfil do IAM

Se estiver sendo executada em cadernos do Amazon EC2 ou SageMaker, o perfil do IAM da instância será usado automaticamente.

Verificar as credenciais

```
import boto3

sts = boto3.client('sts')
identity = sts.get_caller_identity()
print(f"Account: {identity['Account']}")
print(f>User/Role: {identity['Arn']}")
```

Etapa 4: instalar o provedor do SageMaker

O provedor do SageMaker permite que o Inspect AI se comunique com seus endpoints do SageMaker. O processo de instalação do provedor é simplificado no [notebook de início rápido](#).

Etapa 5: fazer o download das avaliações comparativas

Clone o repositório Inspect Evals para acessar as avaliações comparativas padrão:

```
git clone https://github.com/UKGovernmentBEIS/inspect_evals.git
```

Esse repositório inclui avaliações comparativas como:

- MMLU e MMLU-Pro (conhecimento e raciocínio)
- TruthfulQA (veracidade)
- HumanEval (geração de código)
- GSM8K (raciocínio matemático)

Etapa 6: executar avaliações

Execute uma avaliação usando seu endpoint do SageMaker:

```
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
```

Principais parâmetros

Parâmetro	Padrão	Descrição
--max-connections	10	Número de solicitações paralelas para o endpoint. Escale com contagem de instâncias (por exemplo, 10 instâncias × 25 = 250).
--max-retries	3	Tente novamente as solicitações com falha. Use de 50 a 100 para avaliações grandes.
-M region_name	us-east-1	Região da AWS em que seu endpoint está implantado.
-M read_timeout	600	Tempo limite da solicitação em segundos.
-M connect_timeout	60	O tempo limite da conexão em segundos.

Recomendações de ajuste

Para um endpoint de várias instâncias:

```
# 10-instance endpoint example
--max-connections 250    # ~25 connections per instance
--max-retries 100        # Handle transient errors
```

Configurar `--max-connections` muito alto pode sobrecarregar o endpoint e gerar controle de utilização. Configurá-lo muito baixo subutiliza a capacidade.

Etapa 7: visualizar os resultados

Inicie o visualizador do Inspect AI para analisar os resultados da avaliação:

```
inspect view
```

O visualizador exibe:

- Pontuações e métricas gerais
- Resultados por amostra com respostas do modelo
- Análise de erros e padrões de falha

Gerenciar endpoints

Atualizar um endpoint

Para atualizar um endpoint existente com um novo modelo ou configuração:

```
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
)
```

Excluir um endpoint

```
sagemaker.delete_endpoint(EndpointName=ENDPOINT_NAME)
```

Integração de avaliações comparativas personalizadas

Você pode adicionar novas avaliações comparativas ao Inspect AI usando o seguinte fluxo de trabalho:

1. Estude o formato do conjunto de dados e as métricas de avaliação da avaliação comparativa
2. Analisar implementações semelhantes em `inspect_evals/`
3. Crie um arquivo de tarefa que converta registros do conjunto de dados em amostras do Inspect AI
4. Implemente solucionadores e pontuadores apropriados
5. Valide com a execução de um pequeno teste

Exemplo de estrutura de tarefa:

```
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()
    )
```

Solução de problemas

Problemas comuns

Tempos limite ou controle de utilização de endpoints

- Reduza `--max-connections`
- Aumente `--max-retries`

- Verifique as métricas do endpoint do CloudWatch quanto a problemas de capacidade

Erros de autenticação

- Verifique se as credenciais da AWS estão configuradas corretamente
- Verifique se as permissões do IAM incluem `sagemaker:InvokeEndpoint`

Erros de modelo

- Verifique se o endpoint está no status `InService`
- Verifique se o modelo é compatível com o formato da API OpenAI Chat Completions

Recursos relacionados

- [Inspeccionar a documentação de IA](#)
- [Inspeccionar o repositório Evals](#)
- [Guia do desenvolvedor do SageMaker](#)
- [Implantar modelos para inferência](#)
- [Configurando a AWS CLI](#)

Implantação de modelos do Amazon Nova Forge na detecção de abusos da Inferência do Amazon SageMaker

A AWS está comprometida com o uso responsável da IA. Para ajudar a evitar possíveis usos indevidos, quando você implementa modelos do Amazon Nova Forge na Inferência do Amazon SageMaker, ela implementa mecanismos automatizados de detecção de abusos para identificar possíveis violações da [Política de uso aceitável](#) (AUP) e dos Termos de Serviço da AWS, incluindo a [Política de IA responsável](#).

Nossos mecanismos de detecção de abuso são totalmente automatizados, portanto não há análise humana nem acesso às entradas do usuário ou às saídas do modelo.

A detecção automática de abuso inclui:

- Categorizar o conteúdo: usamos classificadores para detectar conteúdo prejudicial (como conteúdo que incita à violência) nas entradas dos usuários e nas saídas dos modelos. Um

classificador é um algoritmo que processa entradas e saídas do modelo e atribui o tipo de dano e nível de confiança. Podemos executar esses classificadores no uso de modelos do Amazon Nova Forge. O processo de classificação é automatizado e não envolve análise humana das entradas ou saídas do usuário modelo.

- Identificar padrões: usamos métricas classificadoras para identificar possíveis violações e comportamentos recorrentes. Podemos compilar e compartilhar métricas de classificadores anonimizadas. A Inferência do Amazon SageMaker não armazena a entrada do usuário ou a saída do modelo.
- Detecção e bloqueio de material de abuso sexual infantil (CSAM): você é responsável pelo conteúdo que carrega (e de seus usuários finais) na Inferência do Amazon SageMaker e deve garantir que ela esteja livre de imagens ilegais. Para ajudar a impedir a disseminação de CSAM, ao implantar um modelo do Amazon Nova Forge na Inferência do Amazon SageMaker, ela pode usar mecanismos automatizados de detecção de abuso (como tecnologia de correspondência de hash ou classificadores) para detectar um possível CSAM. Se a Inferência do Amazon SageMaker detectar um possível CSAM nas entradas de imagens do cliente, ela bloqueará a solicitação e enviará uma mensagem de erro automática. A Inferência do Amazon SageMaker também pode registrar uma denúncia no Centro Nacional para Crianças Desaparecidas e Exploradas (NCMEC) ou em uma autoridade relevante. Levamos o CSAM a sério e continuaremos a atualizar nossos mecanismos de detecção, bloqueio e denúncia. De acordo com as leis aplicáveis, o cliente pode ser obrigado a tomar medidas adicionais e é responsável por essas medidas.

Quando nossos mecanismos automatizados de detecção de abusos identificarem possíveis violações, poderemos solicitar informações sobre o seu uso da Inferência do Amazon SageMaker e sua conformidade com nossos termos de serviço. Caso você se mostre omissa, relutante ou incapaz de cumprir com esses termos ou políticas, a AWS poderá suspender seu acesso à Inferência do Amazon SageMaker. Além disso, você também poderá ser cobrado pela falha no processamento de inferência se nossos testes automatizados detectarem que as respostas do modelo são inconsistentes com nossos termos e políticas.

Em caso de dúvidas, entre em contato com o AWS Support. Para obter mais informações, consulte [Perguntas frequentes sobre o Amazon SageMaker](#).

Inferência do Amazon Bedrock.

Depois de treinar e testar seu modelo do Amazon Nova, você poderá implantá-lo no Amazon Bedrock para inferência em escala de produção. O processo de implantação envolve a criação de

um modelo do Amazon Bedrock com a API `CreateCustomModel`, a exportação dos artefatos do seu modelo de um bucket gerenciado do Amazon S3 e, quando o modelo estiver ATIVO, a configuração de um endpoint com inferência de throughput sob demanda ou provisionada.

Depois de criar um modelo personalizado no SageMaker, você pode usar a API `CreateCustomModel` para implantá-lo no Amazon Bedrock do depósito do SageMaker para executar inferências. Você pode então usar `CreateCustomModelDeployment` para criar um endpoint de inferência de OD ou configurar a inferência de throughput provisionado para um modelo de ajuste fino com eficiência de parâmetros (PEFT). Você pode configurar a inferência de throughput provisionado para um modelo personalizado de full-rank.

Você também pode usar o Amazon Nova Forge SDK para implantar modelos personalizados do Amazon Nova. O Amazon Nova Forge SDK fornece uma experiência simplificada para extrair as informações relevantes de uma tarefa de treinamento ou de um ponto de verificação do modelo do S3 e publicá-los no Amazon Bedrock. Para obter mais informações, consulte [Amazon Nova Forge SDK](#).

Para obter etapas detalhadas para configurar a inferência do Amazon Bedrock para um modelo personalizado, consulte [Implantação de modelos personalizados do Amazon Nova no Amazon Bedrock](#).

A seção a seguir fornece mais detalhes sobre a inferência sob demanda em modelos personalizados.

Implementar um modelo personalizado para inferência sob demanda

Depois de criar com sucesso um modelo personalizado com uma tarefa o de personalização de modelo (ajuste, destilação ou pré-treinamento contínuo), você pode configurar a inferência sob demanda para o modelo.

Para configurar a inferência sob demanda para um modelo personalizado, você implanta o modelo com uma implantação de modelo personalizado. Depois de implantar o modelo personalizado, use o nome do recurso da Amazon (ARN) da implantação como o parâmetro `modelId` nas operações de API `InvokeModel` ou `Converse`. Você pode usar o modelo implantado para inferência sob demanda com os atributos do Amazon Bedrock, como playgrounds, agentes e bases de conhecimentos.

Tópicos

- [Modelos compatíveis](#)

- [Implantar um modelo personalizado](#)
- [Usar uma implantação para inferência sob demanda](#)
- [Excluir uma implantação de modelo personalizado](#)

Modelos compatíveis

Você pode configurar a inferência sob demanda para os seguintes modelos:

- Amazon Nova Canvas
- Amazon Nova Lite
- Amazon Nova Micro
- Amazon Nova Pro

Implantar um modelo personalizado

Você pode implantar um modelo personalizado com o console, a AWS Command Line Interface, ou os AWS SDKs do Amazon Bedrock. Para obter informações sobre o uso da implantação para inferência, consulte [Use a deployment for on-demand inference](#).

Tópicos

- [Implantar um modelo personalizado \(console\)](#)
- [Implantar modelo personalizado \(AWS Command Line Interface\)](#)
- [Implantar modelo personalizado \(AWS SDKs\)](#)

Implantar um modelo personalizado (console)

Você implanta um modelo personalizado na página Modelos personalizados como se segue. Você também pode implantar um modelo na página Modelo personalizado sob demanda com os mesmos campos. Para encontrar essa página, em Inferência e avaliação no painel de navegação, escolha Modelo personalizado sob demanda.

Para implantar um modelo personalizado

1. Faça login no Console de gerenciamento da AWS usando um [perfil do IAM com as permissões do Amazon Bedrock](#) e abra o console do Amazon Bedrock em <https://console.aws.amazon.com/nova/>.

2. No painel de navegação à esquerda, escolha Modelos personalizados em Modelos de base.
3. Na guia Modelos, selecione o botão de opção do modelo que você deseja implantar.
4. Escolha Configurar inferência e Implantar para uso sob demanda.
5. Na página Detalhes da implantação, forneça as seguintes informações:
 - Nome da implantação (obrigatório): insira um nome exclusivo para a implantação.
 - Descrição (opcional): insira uma descrição para a implantação.
 - Tags (opcional): adicione tags para alocação de custos e gerenciamento de recursos.
6. Escolha Criar. Quando o status mostrar Completed, seu modelo personalizado estará pronto para inferência sob demanda. Para obter informações sobre o uso do modelo personalizado, consulte [Use a deployment for on-demand inference](#).

Implantar modelo personalizado (AWS Command Line Interface)

Para implantar um modelo personalizado para inferência sob demanda usando a AWS Command Line Interface, use o comando `create-custom-model-deployment` com o nome do recurso da Amazon (ARN) do modelo personalizado. Esse comando usa a operação de API [CreateCustomModelDeployment](#). Ele retorna o ARN da implantação que você pode usar como o `modelId` ao fazer solicitações de inferência. Para obter informações sobre o uso da implantação para inferência, consulte [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
```

Implantar modelo personalizado (AWS SDKs)

Para implantar um modelo personalizado para inferência sob demanda, use a operação de API [CreateCustomModelDeployment](#) com o nome do recurso da Amazon (ARN) do modelo personalizado. Ela retorna o ARN da implantação que você pode usar como o `modelId` ao fazer solicitações de inferência. Para obter informações sobre o uso da implantação para inferência, consulte [Use a deployment for on-demand inference](#).

O código a seguir mostra como usar o SDK para Python (Boto3) para implantar um modelo personalizado.

```
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
```

Usar uma implantação para inferência sob demanda

Depois de implantar o modelo personalizado para inferência sob demanda, você pode usá-lo para gerar respostas fazendo solicitações de inferência. Para as operações `InvokeModel` ou `Converse`, você usa o nome do recurso da Amazon (ARN) da implantação como o `modelId`.

Para obter informações sobre como fazer solicitações de inferência, consulte os seguintes tópicos:

- [Enviar prompts e gerar respostas com inferência do modelo](#)
- [Pré-requisitos para executar a inferência do modelo](#)
- [Enviar prompts e gerar respostas usando a API](#)

Excluir uma implantação de modelo personalizado

Depois que terminar de usar seu modelo para inferência sob demanda, você poderá excluir a implantação. Depois que excluir a implantação, você não poderá usá-la para inferência sob demanda, mas o modelo personalizado subjacente não será excluído.

Você pode excluir uma implantação de modelo personalizado com o console, a AWS Command Line Interface, ou os AWS SDKs do Amazon Bedrock.

Important

A exclusão de uma implantação de modelo personalizado é irreversível. Certifique-se de que não precisa mais da implantação antes de prosseguir com a exclusão. Se precisar usar o modelo personalizado para inferência sob demanda novamente, você deverá criar uma nova implantação.

Tópicos

- [Excluir uma implantação de modelo personalizado \(console\)](#)
- [Excluir uma implantação de modelo personalizado \(AWS Command Line Interface\)](#)
- [Excluir uma implantação de modelo personalizado \(AWS SDKs\)](#)

Excluir uma implantação de modelo personalizado (console)

Para excluir uma implantação de modelo personalizado

1. No painel de navegação, em Inferência e avaliação, escolha Modelo personalizado sob demanda.
2. Escolha a implantação de modelo personalizado que você deseja excluir.
3. Escolha Excluir.
4. Na caixa de diálogo de confirmação, insira o nome da implantação para confirmar a exclusão.
5. Escolha Delete para confirmar.

O status da implantação mudará para Deleting enquanto a exclusão estiver em andamento. Depois de concluída, a implantação será removida da lista.

Excluir uma implantação de modelo personalizado (AWS Command Line Interface)

Para excluir uma implantação de modelo personalizado usando a AWS Command Line Interface, use o comando `delete-custom-model-deployment` com identificador da implantação.

```
aws bedrock delete-custom-model-deployment \
--custom-model-deployment-identifier "deployment-arn-or-name" \
--region region
```

Excluir uma implantação de modelo personalizado (AWS SDKs)

Para excluir programaticamente uma implantação de modelo personalizado, use a operação da API [DeleteCustomModelDeployment](#) com o nome do recurso da Amazon (ARN) da implantação. O código a seguir mostra como usar o SDK para Python (Boto3) para excluir uma implantação de modelo personalizado.

```
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
```

Inferência sob demanda em modelos personalizados

A inferência sob demanda (OD) permite que você execute inferência em seus modelos personalizados do Amazon Nova sem manter endpoints de throughput provisionados. Isso ajuda a otimizar custos e escalar com eficiência. Com inferência sob demanda, a cobrança é baseada no uso medido em tokens, tanto de entrada quanto de saída.

Requisitos de compatibilidade

Os seguintes requisitos de compatibilidade se aplicam:

- A inferência de OD é compatível com os modelos de compreensão personalizados do Amazon Nova Pro, Lite e Micro. A inferência OD não é compatível com os modelos de geração de conteúdo personalizados do Nova.
- A inferência OD é compatível com os modelos de entendimento personalizados do Amazon Nova treinados depois de 16 de julho de 2025. Modelos personalizados treinados antes de 16 de julho de 2025 não são compatíveis com inferência OD.
- Personalização do Amazon Bedrock: a inferência OD é compatível com modelos personalizados com a personalização do Amazon Bedrock e modelos aprendizes que foram destilados de um modelo instrutor com o Amazon Bedrock.
- Personalização do SageMaker AI: para modelos personalizados no SageMaker AI, a inferência OD é compatível apenas com modelos ajustados com eficiência de parâmetros (PEFT) quando o modelo está hospedado no Amazon Bedrock. Isso inclui a Otimização Direta de Preferências e PEFT. A inferência OD não é compatível com modelos completamente ajustados.

Treinamento de modelo e inferência

Quando você treinar um novo modelo personalizado do Amazon Nova Pro, Lite ou Micro no Amazon Bedrock ou no SageMaker AI usando PEFT após 16 de julho de 2025, o modelo será automaticamente compatível com as opções de inferência provisionada e sob demanda. Você pode selecionar seu método de inferência preferido ao implantar o modelo.

Para usar a inferência OD com um modelo treinado após 16 de julho de 2025, conclua as seguintes etapas:

1. [Crie uma nova tarefa de ajuste com a API de personalização do Amazon Bedrock ou com a API de personalização do SageMaker AI.](#)
2. Implante o modelo recém-treinado no Amazon Bedrock usando a [API CreateCustomModel](#).
3. Implante para inferência sob demanda usando a API CustomModelDeployment.

Limites de taxa

Os seguintes limites de solicitações por minuto (RPM) e tokens por minuto (TPM) se aplicam às solicitações de inferência sob demanda:

Base Model for Custom Model	RPM per Custom Model Deployment	TPM per Custom Model Deployment
Nova 2 Lite	2,000	4,000,000

Para saber mais sobre as cotas disponíveis para o Amazon Nova, consulte [Cotas do Amazon Nova](#).

Latência

Você pode esperar uma diferença de latência de ponta a ponta (ou seja, tempo até o primeiro token (TTFT)) de 20% a 55% entre a invocação do modelo básico e o adaptador. O valor exato da latência varia de acordo com o tamanho do modelo e está dentro dos padrões do setor.

Limitações de personalização de modelos do Amazon Nova

A personalização do Amazon Nova não é compatível com os recursos a seguir do SageMaker.

- SSH na instância para encontrar as métricas

Devido aos controles de segurança em vigor, não é possível executar SSH no nó principal na instância algo-1 de treinamento para encontrar estatísticas de memória ou estatísticas da NVIDIA e validar as etapas de treinamento.

- Suporte ao SDK do treinador do SageMaker

No momento, o treinador do SageMaker não está disponível para iniciar tarefas de treinamento. No momento, você pode iniciar tarefas de treinamento somente por meio da API de estimadores.

- Os grupos de aquecimento não podem ser acessados para tarefas de treinamento do SageMaker

Devido aos controles de segurança em vigor, os grupos de aquecimento do SageMaker não podem ser usados para manter a instância no grupo de aquecimento até o fim da vida útil.

- Mesclagem de modelos personalizados

No momento, não é possível mesclar vários modelos. Isso significa que não é possível criar vários adaptadores de LoRA e executar uma operação de várias mesclagens com o modelo de base.

- Ferramenta de observabilidade compatível

O [TensorBoard](#) é a única ferramenta de observabilidade compatível para visualizar métricas de tarefas de treinamento do SageMaker. No momento, não há suporte para [MLflow](#) ou [WandB](#). Para obter mais informações sobre como usar o TensorBoard no SageMaker, consulte [TensorBoard no SageMaker](#).

Amazon Nova Forge

O Amazon Nova Forge é um serviço inédito que oferece às organizações a maneira mais fácil e econômica de criar seus próprios modelos de fronteira usando o Nova.

O Amazon Nova Forge introduz o conceito de modelos de “treinamento aberto”, que dão às organizações acesso a uma variedade de pontos de verificação de modelos iniciais e a possibilidade de combinar dados proprietários com conjuntos de dados selecionados pela Amazon em cada etapa do treinamento de modelos. Isso permite que os modelos maximizem o aprendizado com dados proprietários e, ao mesmo tempo, minimizem o risco de esquecer habilidades fundamentais, como o raciocínio.

O Nova Forge fornece os principais recursos abaixo:

- Acessar pontos de verificação em todas as fases do desenvolvimento do modelo e aproveitar os novos modelos Nova antes que eles estejam amplamente disponíveis
- Combinar seus dados proprietários com dados de treinamento selecionados pelo Amazon Nova
- Realizar aprendizado por reforço com funções de recompensa em seu ambiente
- Usar fórmulas prontas e otimizadas para criar com o Nova por meio de fluxos de trabalho visuais ou uma interface de linha de comando
- Use o kit de ferramentas de IA responsável para alinhar os modelos às diretrizes de IA responsável do Amazon Nova durante o processo de treinamento e implemente controles de runtime para moderar as respostas do modelo durante a inferência.

Pré-requisitos

Tópicos

- [Inscrever-se no Nova Forge](#)
- [Outros pré-requisitos](#)

Inscrever-se no Nova Forge

Para solicitar acesso ao serviço do Amazon Nova Forge, adicione a seguinte tag ao seu perfil do console do IAM: key forge-subscription with value true. Depois de adicionar essa tag ao seu perfil, acesse Console do SageMaker AI > Treinamento e personalização de modelos e clique em Nova

Forge. Nessa página, você encontrará detalhes sobre o serviço, informações sobre preços e os recursos. Você pode solicitar a inscrição e depois gerenciá-la nesta página.

1. O perfil deve ter permissão para chamar a API `ListAttachedRolePolicy`, e a resposta deve incluir uma política `AdministratorAccess` ou `AmazonSageMakerFullAccess`.
2. O perfil de login deve ter permissão para chamar a API `ListRoleTags`, e as tags de resposta devem incluir `tag.key=forge-subscription`.

Outros pré-requisitos

Além disso, certifique-se de que os seguintes pré-requisitos estejam concluídos:

1. [Pré-requisitos gerais](#)
2. Etapas adicionais para usuários: adicionar grupo de instâncias restritas (RIG) ao seu cluster do SageMaker HyperPod (para concluir, siga as etapas [aqui](#))

Configuração e acesso ao Nova Forge

Para começar a utilizar o Nova Forge, siga este processo de duas etapas:

- Etapa 1: inscrever-se no Nova Forge
- Etapa 2: configurar a infraestrutura do HyperPod

Obtenção dos documentos do Nova Forge

Para obter os documentos do Nova Forge, siga as etapas abaixo:

```
mkdir NovaForgeHyperpodCLI
cd NovaForgeHyperpodCLI
aws s3 cp s3://nova-forge-c7363-206080352451-us-east-1/v1/ ./ --recursive
pip install -e .
```

Etapa 1: inscrever-se no Nova Forge

Resumo rápido:

1. Verifique se você tem acesso de administrador à conta da Amazon Web Services.

2. Navegue até o console do SageMaker AI e solicite acesso ao Nova Forge.
3. Aguarde até que a equipe do Nova envie um e-mail de confirmação depois que sua solicitação de inscrição for aprovada.
4. Marque seu perfil de execução com a tag `forge-subscription`. Essa tag é necessária para acessar os recursos e pontos de verificação do Nova Forge. Adicione a seguinte tag ao seu perfil de execução:
 - Chave: `forge-subscription`
 - Valor: `true`

Guia detalhado

Para se inscrever no Nova Forge e usar efetivamente o serviço de personalização, um cliente da Amazon Web Services deve ter acesso de administrador à sua conta da Amazon Web Services ou solicitar ao administrador que lhe conceda acesso de administrador. Este documento descreve as etapas necessárias para:

- Proteger o acesso de administrador
- Configurar as políticas para se inscrever no Nova Forge
- Acessar fórmulas de personalização
- Configurar a personalização
- Monitorar o fluxo de trabalho
- Avaliar o ponto de verificação do modelo personalizado

Opção A

Fluxo 1: o usuário da conta deve entrar em contato com o administrador da conta para solicitar o seguinte:

- Adicionar a tag `forge-subscription` à conta por meio do IAM (consulte o Apêndice A para verificar as etapas).
- Adicionar as permissões `ListRoleTags` e `ListAttachedRolePolicies` por meio do IAM (consulte o Apêndice B para verificar as etapas).

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

Opção B

Fluxo: o usuário da conta deve entrar em contato com o administrador da conta para solicitar acesso administrativo à conta.

- Depois que o acesso de administrador for concedido, siga as etapas no Fluxo 2.

Fluxo 2. Conta da Amazon Web Services com acesso de administrador

- Adicione a tag forge-subscription à conta por meio do IAM. Verifique as etapas no Apêndice A.

Apêndice A. Adicionar a política forge-subscription à conta da Amazon Web Services

1. Acesse o painel do IAM da Amazon Web Services. Clique em Perfis à esquerda. Procure por administrador e clique no perfil de administrador

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

New

Roles (181) Info

An IAM role is an identity you can create that has specific permissions with credentials that are valid for s

Search admin X 1 match

☐ Role name

☐ [libsAdminAccess-DO-NOT-DELETE](#) Trusted

Roles Anywhere Info

Authenticate your non AWS workloads and securely provide access to AWS services.

Access AWS from your non AWS workloads

Operate your non AWS workloads using the same authentication and authorization strategy that you use within AWS.

X.509 Standard

Use your own existing PKI infrastructure or [Certificate Manager Private Certificate Autl](#) to authenticate identities.

2. Selecione <AssumedRoleToUse> (p. ex., libsAdminAccess). Clique em na guia Tags.

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

New

libsAdminAccess-DO-NOT-DELETE Info

Summary

Creation date
November 06, 2025, 09:29 (UTC-08:00)

Last activity
5 minutes ago

ARN
arn:aws:iam::6s-DO-NOT-DE

Maximum session
1 hour

Permissions Trust relationships **Tags (2)** Last Acce

Tags (2) Info

Tags are key-value pairs that you can add to AWS resources to help identify,

Key

forge-subscription

3. Clique em Gerenciar guias. Adicione uma nova tag. Digite “forge-subscription” em Chave e clique em salvar alterações.

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	Remove
prime-subscription	prime-subscription	Remove

[Add new tag](#)

You can add up to 48 more tags.

[Cancel](#) [Save changes](#)

4. Certifique-se de ver forge-subscription como uma chave na seção Tags.

Identity and Access Management (IAM)

[Search IAM](#)

Access management

- User groups
- Users
- Roles**
- Policies
- Identity providers
- Account settings
- Root access management
- Temporary delegation requests

Access reports

- Access Analyzer
- Resource analysis

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

Apêndice B. Adicionar as políticas ListRoleTags e ListAttachedPolicies à conta da Amazon Web Services para o perfil não administrativo, atribuído por administrador

1. Acesse o painel do IAM da Amazon Web Services. Clique em Perfis à esquerda. Pesquise <AssumedRoleToUse> (p. ex., ForgeAccessRole) e clique no perfil <AssumedRoleToUse> (p. ex., ForgeAccessRole)




2. Clique no perfil <AssumedRoleToUse> (p. ex., ForgeAccessRole) e selecione Tags. Adicionar uma nova tag com o tipo “forge-subscription”



3. Em Permissões, adicione uma nova permissão: Adicionar permissões → Criar política em linha → Adicionar a seguinte política listada abaixo

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "VisualEditor0",
      "Effect": "Allow",
      "Action": [
        "iam:ListRoleTags",
        "iam:ListAttachedRolePolicies"
      ],
      "Resource": "*"
    }
  ]
}
```



The screenshot displays the AWS IAM console interface for the **ForgeAccessRole**. The **Summary** section shows the role was created on December 09, 2025, at 21:31 (UTC-05:00), with an ARN of `arn:aws:iam:::role/ForgeAccessRole`. The last activity was 15 minutes ago. The **Permissions policies (2)** section lists two attached policies: **AmazonSageMakerFullAccess** and **forge-access-role**. The **forge-access-role** policy is expanded, showing its JSON definition:

```
1- {
2-   "Version": "2012-10-17",
3-   "Statement": [
4-     {
5-       "Sid": "VisualEditor0",
6-       "Effect": "Allow",
7-       "Action": [
8-         "iam:ListRoleTags",
9-         "iam:ListAttachedRolePolicies"
10-      ],
11-       "Resource": "*"
12-     }
13-   ]
14- }
```

Etapa 2. Configurar a infraestrutura do HyperPod

Configure a infraestrutura necessária seguindo as [instruções do workshop](#) para configurar o ambiente com recursos habilitados para Forge.

Configurações de moderação de conteúdo

Se você precisar acessar o Nova Forge, as configurações de moderação de conteúdo personalizáveis (CCMS) estão disponíveis para os modelos do Amazon Nova Lite 1.0 e Pro 1.0. O CCMS permite o ajuste dos controles de moderação de conteúdo para se alinhar aos seus requisitos empresariais específicos, mantendo as proteções essenciais de IA responsável. Para determinar se um modelo empresarial é apropriado para o CCMS, entre em contato com um gerente de conta da AWS.

Para obter informações adicionais sobre como configurar e usar o CCMS com modelos personalizados, consulte a [seção Kit de ferramentas de IA responsável e moderação de conteúdo](#).

Pré-treinamento contínuo e treinamento intermediário

Note

A documentação detalhada é fornecida após a inscrição

O CTP do Nova Forge oferece recursos avançados além do CPT padrão, incluindo acesso a pontos de verificação intermediários e uma combinação de dados com o corpus de pré-treinamento do Nova. Esses recursos permitem uma adaptação mais eficiente do domínio e uma melhor preservação dos recursos gerais do modelo.

O que são pontos de verificação intermediários e por que eles são necessários?

Os pontos de verificação intermediários são snapshots do modelo do Amazon Nova salvos em diferentes etapas do pré-treinamento, antes que o modelo atinja seu estado final pronto para produção. Durante o desenvolvimento do modelo, o Amazon Nova passa por várias fases de treinamento: pré-treinamento inicial com taxa de aprendizado constante, redução da taxa de aprendizado, treinamento de extensão de contexto e, finalmente, treinamento de segurança e alinhamento para seguir as instruções. Para o CPT, os pontos de verificação intermediários geralmente são preferíveis ao ponto de verificação final de produção porque são mais plásticos e receptivos à adaptação do domínio. O ponto de verificação de produção passou por um extenso treinamento de segurança e alinhamento para seguir as instruções, o que otimiza o modelo para uso conversacional geral, mas pode torná-lo resistente ao aprendizado de novos padrões específicos de domínio durante o CPT. Por outro lado, os pontos de verificação somente com texto pré-treinado parcial e totalmente mantêm as características de pré-treinamento do modelo. Eles não foram fortemente orientados para comportamentos específicos, o que os torna pontos de partida mais eficientes para a adaptação de domínios. Ao realizar o CPT em grande escala (mais de 10 bilhões de tokens), começar nos pontos de verificação intermediários normalmente resulta em convergência mais rápida, melhor estabilidade de treinamento e aquisição de conhecimento de domínio mais eficaz. No entanto, para o CPT de pequena escala (menos de 10 bilhões de tokens), ou quando os recursos de seguimento de instruções precisam ser preservados, o ponto de verificação de

produção pode ser mais apropriado, pois permite a adaptação do domínio, mantendo as habilidades de conversação do modelo.

Vários pontos de verificação intermediários são necessários para o CPT porque oferecem diferentes níveis de plasticidade do modelo que afetam a eficiência com que o modelo pode absorver novos conhecimentos de domínio. O ponto de verificação de produção passou por um extenso treinamento de segurança e alinhamento para seguir as instruções, o que o otimiza para uso conversacional geral, mas o torna resistente ao aprendizado de novos padrões específicos de domínio. Em outras palavras, foi reforçado durante o pós-treinamento. Em contraste, os pontos de verificação anteriores mantêm as características de pré-treinamento do modelo e não foram fortemente direcionados para comportamentos específicos, tornando-os mais plásticos e receptivos à adaptação do domínio.

Para obter a melhor eficiência de treinamento, vários pontos de verificação intermediários são fornecidos.

Quais pontos de verificação estão disponíveis?

Nova 2.0

Existem três pontos de verificação do Amazon Nova Lite 2.0.

- **PRÉ-TREINADO** - [nova-lite-2/pretraining-text-RD]: este é o ponto de verificação após a taxa de aprendizado constante e as etapas de desaceleração do pré-treinamento do Amazon Nova, em que o modelo é treinado em trilhões de tokens.
- **TREINAMENTO INTERMEDIÁRIO** - [nova-lite-2/pretraining-text-CE]: este ponto de verificação permite que volumes intermediários de dados não estruturados sejam introduzidos com uma taxa de aprendizado mais conservadora do que o pré-treinamento, absorvendo o conhecimento específico do domínio e evitando o esquecimento catastrófico.
- **PÓS-TREINADO** - [nova-lite-2/prod]: este é o ponto de verificação final totalmente alinhado do modelo que passou por todas as etapas pertinentes e posteriores ao treinamento.

A tabela a seguir detalha as diferentes condições para o pré-treinamento e o treinamento intermediário.

Tipo de dado	Executar	Com ponto de verificação
Dados brutos de domínio não estruturados em grande	Pré-treinamento contínuo	Pré-treinado

Tipo de dado	Executar	Com ponto de verificação
escala (documentos, logs, artigos, código etc.)		
Dados brutos de domínio não estruturados em grande escala (documentos, logs, artigos, código etc.)	Treinamento intermediário	Pré-treinado
Volumes menores de dados brutos não estruturados. Rastros de raciocínio estruturado/dados de CoT	Treinamento intermediário	Treinamento intermediário
Demonstrações estruturadas (pares de entrada e saída de alta qualidade, instruções de tarefas selecionadas, diálogos de várias etapas)	Ajuste fino completo	Treinamento intermediário
Demonstrações estruturadas (pares de entrada e saída de alta qualidade, instruções de tarefas selecionadas, diálogos de várias etapas)	Ajuste fino com eficiência de parâmetros	Pós-treinado

Qual ponto de verificação usar?

Pontos de verificação parcialmente e totalmente pré-treinados apenas com texto geralmente convergem mais rápido e exigem menos etapas de treinamento para adaptação de domínio. No entanto, eles não têm ajuste de instruções e precisariam passar por etapas de pós-treinamento para serem capazes de realizar tarefas úteis e seguir instruções. Um ponto de verificação GA pode exigir mais etapas para se adaptar, mas fornece um ponto de partida mais seguro para experimentos em pequena escala e manterá algumas de suas capacidades pós-treinamento, mesmo após o treinamento do CPT.

Em geral, com grandes conjuntos de dados de treinamento (mais de 10 bilhões de tokens), comece com pontos de verificação parcialmente ou totalmente pré-treinados somente com texto para um treinamento mais eficiente e estável, pois a base de conhecimento do modelo será substancialmente modificada. Com conjuntos de dados pequenos (menos de 10 bilhões de tokens), use o ponto de verificação GA para preservar os recursos de seguimento de instruções e, ao mesmo tempo, adaptar-se ao domínio.

Como usar a combinação de dados do Nova 2.0?

Ao realizar o CPT com dados de um novo domínio, é extremamente benéfico combinar os novos dados com alguns dos dados usados anteriormente na fase de pré-treinamento do modelo.

Combinar dados antigos com dados de novos domínios soluciona dois problemas:

- **Esquecimento do controle:** evita o esquecimento catastrófico, preservando as habilidades e o conhecimento existentes do modelo. Sem a combinação de dados, o treinamento exclusivo em dados de domínio restrito faz com que o modelo substitua os recursos gerais. Por exemplo, um modelo treinado somente em documentos legais pode perder a capacidade de codificar ou fazer cálculos. A combinação dos conjuntos de dados de domínio geral preserva essas habilidades gerais ao adquirir o novo domínio.
- **Estabilidade de otimização:** mantém a estabilidade do treinamento servindo como uma âncora para as representações internas do modelo. Durante o CPT, os recursos aprendidos do modelo são modificados e a combinação de dados fornece gradientes de diversas fontes que orientam essa adaptação sem problemas. Sem isso, o treinamento em distribuições restritas pode causar instabilidade de gradiente, em que as representações do modelo mudam de forma significativa, levando a divergências de treinamento, picos de perda ou colapso dos recursos existentes. Este é o equilíbrio entre estabilidade e plasticidade: o modelo deve ser plástico o suficiente para aprender novos conhecimentos de domínio, mas estável o suficiente para não comprometer o que ele já sabe.

Recursos da combinação de dados do CTP do Nova

O acesso aos dados e pontos de verificação de pré-treinamento do Amazon Nova é uma das principais ofertas da personalização do CPT do Amazon Nova. A personalização do CPT do Amazon Nova permite a fácil combinação de dados de domínio com o corpus de pré-treinamento do Amazon Nova. Além disso, a proporção de amostragem das categorias de dados específicas do Amazon Nova (p. ex., código, cálculo, raciocínio etc.) pode ser alterada, e suas proporções podem ser

controladas para complementar os dados do domínio. Isso permite o reforço de recursos que se alinham ao caso de uso e, ao mesmo tempo, adaptam o modelo ao domínio específico.

Busca pela proporção ideal da combinação

A proporção ideal de dados do Amazon Nova versus dados de domínio depende do domínio, da complexidade, do tamanho, da qualidade e da importância de manter os recursos gerais do conjunto de dados. Essa proporção deve ser descoberta por meio de experimentação. Abaixo, um framework experimental para decidir a quantidade de dados do Amazon Nova a serem combinados.

Selecione um subconjunto representativo de dados de domínio (p. ex., 5 bilhões de tokens) e mantenha isso constante em todas as execuções experimentais.

Execute experimentos de CPT em pequena escala variando apenas a quantidade de dados do Amazon Nova combinados em:

- Nenhuma combinação: 100% domínio → 5B somente domínio (total de 5 bilhões)
- Combinação leve: 90% domínio → 5B domínio + ~0,56B Amazon Nova (total de aproximadamente 5,56 bilhões)
- Combinação média: 70% domínio → 5B domínio + ~2,14B Amazon Nova (total de aproximadamente 7,14 bilhões)
- Combinação pesada: 50% domínio → 5B domínio + 5B Amazon Nova (total de 10 bilhões)

Avalie cada ponto de verificação nas avaliações comparativas do domínio e do domínio geral. Avalie também o ponto de verificação inicial (ponto de verificação do Amazon Nova antes de qualquer treinamento).

- A performance no domínio do cliente permanece praticamente constante em todas as execuções? Geralmente permanece, já que cada execução processou o mesmo número de tokens de domínio. Se a performance do domínio melhorar com mais combinação, os dados do Amazon Nova fornecerão uma regularização útil.
- As pontuações gerais das avaliações comparativas melhoram à medida que a combinação aumenta?
 - O comportamento esperado é que os recursos gerais melhorem monotonicamente à medida que mais dados do Amazon Nova são adicionados.
 - Analise várias avaliações comparativas gerais: MMLU (conhecimento geral), HumanEval (codificação), GSM8K (cálculo) ou avaliações comparativas específicas de interesse.

- Selecione a proporção de combinação que mantém a performance do domínio e, ao mesmo tempo, fornece recursos gerais aceitáveis para os casos de uso. Considere o custo adicional do treinamento com mais combinação de dados.

Depois que a proporção da combinação ideal for identificada, execute o CPT em grande escala usando o conjunto de dados de domínio completo com a proporção da combinação selecionada.

Dissecação das categorias de combinação de dados

Abaixo, dissecamos cada categoria disponível na combinação de dados para que você tome a melhor decisão sobre quais categorias de dados são as mais adequadas para serem representadas em sua combinação geral de dados.

Como habilitar a combinação de dados

Adicione a seção `data_mixing` à sua fórmula com a distribuição percentual apropriada nas categorias do conjunto de dados. As porcentagens de `nova_data` devem totalizar 100.

Configuração do Nova 2.0 com combinação de dados

```
# 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

```

O que essas categorias significam

Observação: o Nova 2.0 inclui categorias adicionais específicas de raciocínio (p. ex., reasoning-code, reasoning-math, reasoning-instruction-following) que não estão disponíveis no Nova 1.0.

Resumo das categorias e os rótulos de informações:

Nome da categoria	Detalhes das informações
agents	Dados de treinamento focados na tomada de decisão autônoma, na conclusão de tarefas e no comportamento orientado a metas em sistemas de IA
baseline	Dados linguísticos fundamentais focados na compreensão geral, na comunicação básica e nas capacidades linguísticas essenciais
chat	Trocas conversacionais demonstrando um fluxo natural de diálogo, a manutenção do contexto e interações sociais apropriadas
code	Código fonte de programação, documentação e discussões técnicas de várias plataformas e linguagens de programação.
factuality	Materiais de referência e informações verificadas com foco na precisão, na validação da fonte e na avaliação da verdade
identity	Frameworks de personalidade e padrões comportamentais focados em traços de caráter, valores e estilos de interação consistentes

Nome da categoria	Detalhes das informações
long-context	Textos extensos e narrativas complexas focados em manter a coerência e a relevância em interações de longa duração
math	Conteúdo matemático, incluindo livros didáticos, problemas, soluções e discussões matemáticas.
rai	Casos e cenários enfatizando os princípios éticos da IA, considerações de segurança e implantação responsável de tecnologia
instruction-following	Exemplos de execução precisa de tarefas com base em diversos níveis de prompts e diretrizes dos usuários
stem	Conteúdo técnico que abrange ciência, tecnologia, engenharia e matemática, incluindo resolução de problemas e conceitos teóricos
planning	Sequências que demonstram pensamento estratégico, divisão de tarefas passo a passo e alocação eficiente de recursos
reasoning-chat	Cenários de diálogo analítico focados em discussões lógicas e fluxos de conversação estruturados
reasoning-code	Desafios de programação e problemas algorítmicos focados no desenvolvimento sistemático de soluções
reasoning-factuality	Cenários de avaliação de informações focados em processos críticos de avaliação e verificação
reasoning-instruction-following	Análise complexa de tarefas focada na interpretação sistemática e na execução metódica
reasoning-math	Cenários matemáticos de resolução de problemas focados em progressão lógica e estratégias de solução
reasoning-planning	Cenários de tomada de decisão estratégica focados na abordagem sistemática para o alcance de metas

Nome da categoria	Detalhes das informações
<code>reasoning-rag</code>	Cenários de recuperação e síntese de informações focados na compreensão contextual e na aplicação relevante
<code>reasoning-rai</code>	Cenários de tomada de decisão ética focados na avaliação sistemática da segurança e imparcialidade da IA
<code>reasoning-stem</code>	Cenários científicos de resolução de problemas focados na análise metódica e no desenvolvimento de soluções
<code>rag</code>	Exemplos de combinação eficaz do conhecimento externo recuperado com as respostas geradas para fornecer informações contextuais precisas
<code>translation</code>	Pares de conteúdo em vários idiomas que mostram uma tradução precisa, preservando o contexto, o tom e as nuances culturais

Guia de parâmetros

- `dataset_catalog`: por enquanto, o único valor é `cpt_text_lite`, até habilitarmos o treinamento multimodal.
- `nova_data`: porcentagem das categorias individuais de dados do Nova quando combinadas. Elas devem totalizar 1,0.
- `customer_data`: a porcentagem dos dados do cliente combinados com os dados do Nova.

O número total de tokens usados no treinamento pode ser calculado em $\text{max\_length} * \text{global\_batch\_size} * \text{max\_steps}$

Limitações

O CPT atual é compatível apenas com dados de texto e não é compatível com nenhum conjunto de dados multimodais do cliente.

Ajuste fino supervisionado

Introdução

O ajuste fino supervisionado usa um conjunto de dados com pares de entrada-saída para a tarefa de interesse. Em outras palavras, você fornece exemplos de prompts (perguntas, instruções etc.) junto com as respostas corretas ou desejadas e continua treinando o modelo com base nelas. Os pesos do modelo são ajustados para minimizar uma perda supervisionada, normalmente entropia cruzada entre suas previsões e os tokens de resposta esperados.

Quando usar o SFT?

O SFT é melhor quando você tem uma tarefa bem definida com as saídas desejadas claras. Se você puder dizer explicitamente “Dada a entrada X, a saída correta/desejada é Y” e reunir exemplos desses mapeamentos X-Y, o ajuste fino supervisionado será uma ótima opção. Alguns cenários em que o SFT se destaca incluem:

- Tarefas de classificação estruturadas ou complexas: p. ex., classificar documentos ou contratos internos em várias categorias personalizadas. Com o SFT, o modelo pode aprender essas categorias específicas muito melhor do que apenas gerando prompts.
- Tarefas de respostas ou transformação de perguntas com respostas conhecidas: p. ex., ajustar um modelo para responder a perguntas da base de conhecimento de uma empresa ou converter dados entre formatos, em que cada entrada tem uma resposta correta.
- Formatação e consistência de estilo: se você precisar que o modelo sempre responda em um determinado formato ou tom, você pode ajustar exemplos do formato/tom correto. Por exemplo, o treinamento em pares de prompt-resposta que demonstram a voz ou o estilo de uma marca específica pode ensinar ao modelo esse estilo em seus resultados. O comportamento de seguir as instruções geralmente é ensinado logo de início via SFT em exemplos selecionados de bom comportamento do assistente.

O SFT é a maneira mais direta de ensinar a um LLM uma nova habilidade ou comportamento quando você pode especificar qual é o comportamento correto. Ele aproveita a compreensão da linguagem existente do modelo e a concentra em sua tarefa. Não use o SFT quando a lacuna de conhecimento em vez de comportamento; isso não fará com que o modelo aprenda novos fatos, jargões ou eventos recentes. Nesses casos, prefira o pré-treinamento contínuo em grandes corpora do domínio ou a geração aumentada via recuperação (RAG) para fornecer conhecimento externo na inferência. Quando você pode avaliar a qualidade, mas não consegue rotular uma única resposta

certa, o ajuste fino por reforço com recompensas verificáveis ou um LLM como avaliador pode ser preferível ao SFT.

Dependendo da complexidade da tarefa e da performance do modelo Nova sem ajustes, planeje de milhares a dezenas de milhares de demonstrações por tarefa, com a qualidade, a consistência e a diversidade de dados sendo mais importantes do que o volume bruto.

Quando usar o ajuste eficiente de parâmetros e quando usar o SFT full-rank?

As fórmulas de personalização do Nova permitem que você execute parâmetros com eficiência, em particular LoRA ou SFT full-rank. Se você deseja uma atualização de modelo direta e econômica, ou se tem poucos dados, prefira métodos eficientes em termos de ajuste de parâmetros para treinar adaptadores pequenos e deixar a maior parte da estrutura intocada (o SFT full-rank atualiza todos os parâmetros do modelo).

Combinação de dados para o SFT

A combinação de dados permite que você combine seus conjuntos de dados de treinamento personalizados com os dados de treinamento proprietários do Nova. Esse recurso está disponível para os modelos Nova 1.0 e Nova 2.0.

Tipo de dados proprietários do Nova: o Nova é compatível com tipos de dados SFT de texto e multimodais. Ele é organizado em várias categorias de dados, cada uma contendo uma combinação de tarefas relevantes para a categoria correspondente.

Categorias de dados proprietários do Nova: os conjuntos de dados de texto incluem várias categorias, incluindo: tomada de decisão autônoma, conclusão de tarefas, conjuntos de dados orientados a metas (agentes), conjuntos de dados de execução de tarefas precisos com e sem raciocínio (seguimento de instruções com raciocínio, seguimento de instruções), sequências que demonstram pensamento estratégico e divisão de tarefas passo a passo (planejamento), IA responsável (rai), contexto longo, factualidade, matemática, áreas de exatas e muitas outras. Da mesma forma, conjuntos de dados multimodais incluem vídeos, capturas de tela, gráficos e muito mais.

O recurso de combinação de dados permite que você combine suas próprias amostras de treinamento de ajuste fino com amostras dos conjuntos de dados do Nova usados para ajustar o Nova. Isso pode evitar o sobreajuste de seu treinamento personalizado e o “esquecimento

catastrófico” dos recursos do Nova, ou pode ajudar a desenvolver recursos ao treinar em um novo ponto de verificação pré-treinado.

Para combinar dados do Nova, basta adicionar um bloco `data_mixing` ao arquivo YAML da fórmula, na seção `training_config`. Os blocos de combinação de dados de texto e multimodais têm tipos de conteúdo diferentes. Consulte as fórmulas correspondentes.

Modelos compatíveis

- Nova 2.0 Lite

Modalidades compatíveis

- Texto
- Multimodal

Exemplos de configuração YAML

Exemplo de configuração do 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
```

Combinação de dados de texto do 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
```

Combinação de dados multimodais do 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
```

Pontos de verificação do modelo

Pontos de verificação do Nova 2.0

- PRÉ-TREINADO [nova-lite-2/pretraining-text-RD]: ponto de verificação após uma taxa de aprendizado constante e etapas de desaceleração, em que o modelo é treinado em trilhões de tokens. [Resultado da etapa 2]
- TREINAMENTO INTERMEDIÁRIO [nova-lite-2/pretraining-text-CE]: permite que clientes com volumes intermediários de dados não estruturados apresentem seus dados com uma taxa de aprendizado mais conservadora do que a do pré-treinamento, absorvendo conhecimento específico do domínio e evitando um esquecimento catastrófico. [Resultado da etapa 3]
- FINAL [nova-lite-2/prod]: ponto de verificação final totalmente alinhado que passou por todas as etapas de pré-treinamento e pós-treinamento. [Resultado da etapa 4]

Etapas de treinamento:

- Etapa 1: ponto de verificação de PT, pré-treinamento inicial com taxa de aprendizado constante
- Etapa 2: ponto de verificação de PT, desaceleração da taxa de aprendizado
- Etapa 3: ponto de verificação de PT, treinamento de extensão de contexto
- Etapa 4: treinamento de segurança e alinhamento para seguir as instruções

Abordagens de treinamento

Guia de seleção da abordagem de treinamento

Tipo de dado	Volume de dados	Executar	Com ponto de verificação
Dados brutos de domínio não estruturados em grande escala (documentos, logs, artigos, código etc.)	Mais de 1 trilhão de tokens	Pré-treinamento contínuo	Fim da taxa de aprendizado constante (CLR)
Dados brutos de domínio não estruturados em grande escala	Mais de 100 bilhões de tokens	Treinamento intermediário	Fim da CLR
Volumes menores de dados brutos não estruturados; rastros de raciocínio estruturado/dados de CoT	Mais de 1 bilhão de tokens	Treinamento intermediário	Modelo de base do Nova
Demonstrações estruturadas (pares de entrada e saída de alta qualidade, instruções de tarefas selecionadas, diálogos de várias etapas)	Mais de 1 mil exemplos	Ajuste fino supervisionado (SFT)	Modelo de base do Nova

Pré-requisitos antes de começar

- Presumimos que você já tenha configurado um cluster do SMHP com um grupo de instâncias restritas (RIG) com capacidade ativa. Caso contrário, consulte aqui para concluir a configuração do cluster do SMHP e do RIG [[Link do documento](#), [Link do workshop](#)]
- Você precisará de instâncias p5.48xlarge do EC2 para executar essa fórmula. O número mínimo de instâncias necessárias para executar essa fórmula com eficiência é o seguinte:
 - Nova Lite 2.0: 4 p5.48xlarge
- Instale a CLI do SageMaker HyperPod específica para o Forge usando as instruções fornecidas [aqui](#)
- Confirme se você pode se conectar ao cluster usando `hyperpod get-clusters`
 - Observe que esse comando listará todos os clusters do SMHP em sua conta
- Confirme se seu treinamento e, opcionalmente, os dados de validação, estão disponíveis em um bucket do S3 que pode ser acessado pelo perfil de execução do seu cluster do SMHP. Para preparação de dados, consulte a próxima seção.
- Conclua a configuração. Se você não tiver concluído a configuração, siga o [guia](#) abaixo.
- Verificação: depois de concluir a configuração, confirme se você pode executar com êxito os comandos abaixo

```
aws sagemaker describe-cluster --cluster-name <cluster-name> --region <region>

hyperpod connect-cluster --cluster-name cluster-name
```

Uma abordagem sistemática para obter êxito no SFT

- Preparação de dados: siga as diretrizes estabelecidas para criar, limpar ou reformatar conjuntos de dados na estrutura necessária. Certifique-se de que as entradas, saídas e informações auxiliares (como metadados e rastros de raciocínio) estejam alinhadas e formatadas adequadamente.
- Configuração de treinamento: defina como o modelo será treinado. Ao usar o Amazon SageMaker HyperPod, essa configuração é gravada em um arquivo de fórmula YAML, que inclui:
 - Caminhos da fonte de dados (conjuntos de dados de treinamento e validação)

- Hiperparâmetros principais (número de etapas de treinamento, taxa de aprendizado, tamanho do lote)
- Componentes opcionais (parâmetros de treinamento distribuídos etc.)
- Configuração da combinação de dados (define as proporções das categorias de dados do cliente e do Nova)
- Otimização dos hiperparâmetros do SFT: os valores dos parâmetros da fórmula do SFT que recomendamos são um excelente ponto de partida e uma escolha robusta. Se você quiser otimizá-los ainda mais para seu caso de uso, faça várias execuções de SFT com diferentes combinações de parâmetros e escolha a melhor. Você pode selecionar combinações de parâmetros seguindo o método de otimização de hiperparâmetros de sua escolha. Uma abordagem simples é variar o valor de um parâmetro (padrão*0,5, padrão, padrão*2) mantendo outro valor padrão para outros parâmetros, repetir isso para cada parâmetro que você deseja otimizar e iterar, se necessário. Os parâmetros mais relevantes para LoRA são taxa de aprendizado, alfa (parâmetro de escalabilidade), número de épocas para treinar e etapas de aquecimento; para full-stack, é principalmente a taxa de aprendizado, o número de épocas e as etapas de aquecimento.

Sequenciamento de experimentos e combinação de dados

- Se você tem apenas dados do SFT (treinamento/dev/teste) para um conjunto de tarefas e seu foco é apenas na performance do teste nessas tarefas
 - Faça o SFT sem combinar no ponto de verificação do Nova [FINAL]. Use os hiperparâmetros padrão do SFT e, opcionalmente, otimize-os para seu caso de uso. Monitore as métricas de validação e avalie pontos de verificação intermediários para conjuntos de dados maiores.
- Se você tem apenas dados do SFT (treinamento/dev/teste) para um conjunto de tarefas e seu foco é na performance dos testes nessas tarefas e nas avaliações comparativas gerais no domínio de interesse
 - Comece fazendo a combinação de dados do SFT com o Nova em um ponto de verificação de pré-treinamento (ponto de verificação PRÉ-TREINADO ou INTERMEDIÁRIO, não o FINAL). O uso de um ponto de verificação intermediário permite que o modelo integre melhor seus dados personalizados aos dados proprietários do Nova, preservando seus recursos gerais de forma robusta.
 - Execute treinamentos de SFT mais curtos com quantidades variáveis de dados do Nova na combinação (p. ex., 10%, 25%, 50%, 75%) e seleções de categorias de dados do Nova que complementam seu caso de uso (p. ex., escolha a categoria de seguimento de instruções se seu foco for na habilidade de seguir instruções gerais). Monitore as métricas de validação e

avaliar se a combinação ajuda na performance das avaliações comparativas gerais. Selecione a combinação de treinamento e o ponto de verificação que levam à melhor combinação de performance em sua tarefa e performance geral. Dependendo do caso de uso, tanto a tarefa quanto a performance geral podem ser aprimoradas ainda mais usando o ajuste fino por reforço (RFT).

Preparar o conjunto de dados para o SFT

Nova 2.0: use o formato da API Converse <https://docs.aws.amazon.com/bedrock/latest/userguide/conversation-inference-call.html>. O formato de dados do Nova 2.0 pode conter campos de raciocínio adicionais: https://docs.aws.amazon.com/bedrock/latest/APIReference/API_runtime_ReasoningContentBlock.html

O conteúdo de raciocínio captura as etapas intermediárias do pensamento do modelo antes de gerar uma resposta final. Na vez de `assistant`, use o campo `reasoningContent` para incluir rastros de raciocínio. Use texto simples para conteúdo de raciocínio, evite tags de marcação como `<thinking>` e `</thinking>`, a menos que sejam especificamente exigidas por sua tarefa, e garanta que o conteúdo de raciocínio seja claro e relevante para o processo de solução de problemas.

Métodos de avaliação

Pré-requisitos

- URI do ponto de verificação do S3 do arquivo `manifest.json` da sua tarefa de treinamento (para modelos treinados)
- Conjunto de dados de avaliação enviado para o S3 no formato correto
- Caminho do S3 de saída para os resultados da avaliação

Avaliações comparativas prontas para uso: use avaliações comparativas prontas para uso para validar a performance em tarefas gerais. Para obter mais detalhes, confira aqui: <https://docs.aws.amazon.com/sagemaker/latest/dg/nova-hp-evaluate.html>

Traga seus próprios dados

Você também pode fornecer seus dados personalizados formatando-os no formato abaixo e, em seguida, usando os contêineres mencionados a seguir para obter resultados de inferência junto com probabilidades logarítmicas para calibrações, se necessário.

Crie um arquivo JSONL por tarefa com a seguinte estrutura:

```
{
  "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"
}
```

Os resultados gerados durante a fase de inferência da tarefa de avaliação terão a seguinte estrutura:

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

Descrições dos campos:

- **prompt**: entrada formatada enviada ao modelo
- **inference**: resposta gerada do modelo
- **gold**: resposta correta esperada do conjunto de dados de entrada, campo de resposta da entrada
- **metadata**: metadados opcionais transmitidos da entrada

Preparar a configuração da avaliação

Comando para iniciar a tarefa de avaliação. Use "--override-parameters" para modificar qualquer entrada da fórmula.

```
hyperpod start-job -n kubeflow \
  --recipe evaluation/nova/nova_micro_p5_48x1_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"
}'
```

Práticas recomendadas

- Priorize a qualidade dos dados em detrimento do volume: dados de treinamento de alta qualidade, diversos e representativos são mais valiosos do que grandes quantidades de dados de baixa qualidade.
- Inclua a categoria de seguimento de instrução com raciocínio: ao usar a combinação de dados, inclua a categoria de “seguimento de instrução com raciocínio” para manter uma forte performance genérica em todas as tarefas.
- Use as taxas de aprendizado padrão: comece com as taxas de aprendizado padrão (1e-5 para LoRA, 5e-6 para SFT full-stack) e ajuste somente se necessário com base nas métricas de validação.
- Equilibre a combinação de dados do Nova: combine no máximo 50% de dados do Nova para obter um equilíbrio ideal entre latência e performance. Porcentagens mais altas podem melhorar os recursos gerais, mas podem aumentar o tempo de treinamento.
- Monitore as métricas de validação: avalie regularmente os pontos de verificação intermediários durante o treinamento para detectar precocemente o sobreajuste ou a degradação da performance.
- Teste em conjuntos de dados representativos: garanta que seus conjuntos de dados de avaliação representem com precisão seus casos de uso de produção para uma avaliação significativa da performance.

Preparar a configuração da tarefa de treinamento

Hiperparâmetros

Conjunto completo de hiperparâmetros além da combinação de dados:


```

## 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:
    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,
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)

```

Os parâmetros mais relevantes para LoRA são taxa de aprendizado, alfa (parâmetro de escalabilidade), número de épocas para treinar e etapas de aquecimento; para full-stack, é principalmente a taxa de aprendizado, o número de épocas e as etapas de aquecimento. As fórmulas são pré-preenchidas com os padrões recomendados.

Configurar o bloco de combinação de dados

Adicione a seção `data_mix` à sua fórmula com a distribuição percentual apropriada nas categorias do conjunto de dados.

Abaixo, descrevemos cada categoria de dados disponível do Nova.

Configuração do Nova 2.0 com combinação de dados

```

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
```

O que essas categorias significam?

Categorias de dados de texto do Nova 2.0

Nome da categoria	Detalhes das informações
agentes	Dados de treinamento focados na tomada de decisão autônoma, na conclusão de tarefas e no comportamento orientado a metas em sistemas de IA
linha de base	Dados linguísticos fundamentais focados na compreensão geral, na comunicação básica e nas capacidades linguísticas essenciais

Nome da categoria	Detalhes das informações
chat	Trocas conversacionais demonstrando um fluxo natural de diálogo, a manutenção do contexto e interações sociais apropriadas
código	Código fonte de programação, documentação e discussões técnicas de várias plataformas e linguagens de programação.
factualidade	Materiais de referência e informações verificadas com foco na precisão, na validação da fonte e na avaliação da verdade
identidade	Frameworks de personalidade e padrões comportamentais focados em traços de caráter, valores e estilos de interação consistentes
long-context	Textos extensos e narrativas complexas focados em manter a coerência e a relevância em interações de longa duração
math	Conteúdo matemático, incluindo livros didáticos, problemas, soluções e discussões matemáticas.
IA responsável (RAI)	Casos e cenários enfatizando os princípios éticos da IA, considerações de segurança e implantação responsável de tecnologia
seguimento de instruções	Exemplos de execução precisa de tarefas com base em diversos níveis de prompts e diretrizes dos usuários
radical	Conteúdo técnico que abrange ciência, tecnologia, engenharia e matemática, incluindo resolução de problemas e conceitos teóricos

Nome da categoria	Detalhes das informações
planejamento	Sequências que demonstram pensamento estratégico, divisão de tarefas passo a passo e alocação eficiente de recursos
reasoning-chat	Cenários de diálogo analítico focados em discussões lógicas e fluxos de conversação estruturados
reasoning-code	Desafios de programação e problemas algorítmicos focados no desenvolvimento sistemático de soluções
reasoning-factuality	Cenários de avaliação de informações focados em processos críticos de avaliação e verificação
reasoning-instruction-following	Análise complexa de tarefas focada na interpretação sistemática e na execução metódica
reasoning-math	Cenários matemáticos de resolução de problemas focados em progressão lógica e estratégias de solução
reasoning-planning	Cenários de tomada de decisão estratégica focados na abordagem sistemática para o alcance de metas
reasoning-rag	Cenários de recuperação e síntese de informações focados na compreensão contextual e na aplicação relevante
reasoning-rai	Cenários de tomada de decisão ética focados na avaliação sistemática da segurança e imparcialidade da IA

Nome da categoria	Detalhes das informações
reasoning-stem	Cenários científicos de resolução de problemas focados na análise metódica e no desenvolvimento de soluções
RAG	Exemplos de combinação eficaz do conhecimento externo recuperado com as respostas geradas para fornecer informações contextuais precisas
conversão	Pares de conteúdo em vários idiomas que mostram uma tradução precisa, preservando o contexto, o tom e as nuances culturais

Combinação de dados multimodais (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
```

Observação: o Nova 2.0 inclui suporte para categorias de dados de vídeo que não está disponível no Nova 1.0.

O que essas categorias significam?

Categorias de dados multimodais do Nova 2.0

Nome da categoria	Detalhes das informações
grafos	Representações visuais e descrições de gráficos, gráficos circulares, gráficos de barras, gráficos de linhas e outras visualizações estatísticas para ajudar o modelo a entender e a comunicar informações quantitativas de forma eficaz
chat	Dados conversacionais combinados com elementos visuais focados na compreensão contextual do diálogo e nas interações baseadas em imagens
código	Interfaces de programação e ambientes de desenvolvimento focados na interpretação visual do código, capturas de tela do IDE e diagramas técnicos
docs	Dados centrados em documentos que combinam texto, imagens, layouts e formatação para treinar modelos na compreensão e no processamento de vários tipos e estruturas de documentos para ajudar com conceitos como reconhecimento de conteúdo em PDF
general	Conteúdo textual visual diversificado focado na ampla compreensão de imagens, gráficos e texto descritivo que o acompanha
grounding	Materiais de referência visual e imagens rotuladas focados em conectar conceitos de linguagem a representações visuais do mundo real

Nome da categoria	Detalhes das informações
RAG	Exemplos de recuperação multimodal que mostram como combinar e referenciar com eficácia o conhecimento externo visual e textual para gerar respostas contextuais precisas
captura de tela	Capturas de interface de aplicações e imagens de exibição digital com foco na compreensão de interfaces de software e interações digitais
texto	Um conjunto equilibrado de dados contextuais de texto criado com base nas categorias dos conjuntos de dados do SFT somente com texto do Nova para fornecer recursos generalistas
conversão	Conteúdo visual multilíngue focado na interpretação multilíngue de texto em imagens e elementos visuais culturais
video	Conteúdo visual baseado em movimento focado na compreensão temporal e na compreensão visual-narrativa sequencial

Como iniciar uma tarefa

Você também pode consultar o README, se precisar apenas obter os detalhes essenciais para iniciar a primeira execução do SFT.

Informações dos contêineres:

Informações dos contêineres e comandos de inicialização

Modelo	Técnica	Subcategory	URI da imagem	Comando do inicializador do Hyperpod
Nova 2.0	Ajustar	Texto de SFT	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-SFT-V2-latest	hyperpod start-job \ -n kubeflow \ --recipe fine-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/nova-fine-tune-repo:SM-HP-SFT-V2-latest" }'
Nova 2.0	Ajustar	Texto de SFT + combinação de dados	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-SFT-V2-DATAMIXING-latest	hyperpod start-job \ -n kubeflow \ --recipe fine-tuning/nova/forge/nova_2_0/nova_lite/SFT/nova_lite_2_0_p5_gpu_sft_ext_with_datamix

Modelo	Técnica	Subcategory	URI da imagem	Comando do inicializador do Hyperpod
				<pre>\ --override-parameters {'instance_type': "ml.p5.48xlarge", "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-SFT-V2-DATAMIXING-latest" }</pre>

Modelo	Técnica	Subcategory	URI da imagem	Comando do inicializador do Hyperpod
Nova 2.0	Ajustar	SFT multimodal	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-SFT-V2-latest	hyperpod start-job \ -n kubeflow \ --recipe fine-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/nova-fine-tune-repo:SM-HP-SFT-V2-latest" }'

Modelo	Técnica	Subcategory	URI da imagem	Comando do inicializador do Hyperpod
Nova 2.0	Ajustar	SFT multimodal + combinação de dados	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-SFT-V2-DATAMIXING-latest	hyperpod start-job \ -n kubeflow \ --recipe fine-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/nova-fine-tune-repo:SM-HP-SFT-V2-DATAMIXING-latest" }'

Quando estiver tudo configurado, começando pela raiz do repositório sagemaker-hyperpod-cli, navegue até a pasta padrão de fórmulas do SFT do Nova

- `cd /src/hyperpod_cli/sagemaker_hyperpod_recipes/recipes_collection/recipes/training/nova/`
- Aqui você pode escolher se deseja executar fórmulas do Nova 1 ou do Nova 2 com base na escolha do modelo de base.

No SFT do Nova 2.0:

- Se quiser usar uma tarefa regular do SFT, você deverá encontrar uma fórmula nesta pasta
 - `cd /src/hyperpod_cli/sagemaker_hyperpod_recipes/recipes_collection/recipes/fine-tuning/nova_2_0/nova_lite/SFT` and then you should be able to see one recipe under this folder called `nova_lite_2_0_p5x8_gpu_sft.yaml`
- Se você quiser usar uma tarefa de combinação de dados do SFT, é possível navegar até a pasta de fórmulas do SFT do Forge
 - `cd /src/hyperpod_cli/sagemaker_hyperpod_recipes/recipes_collection/recipes/fine-tuning/nova/forge/nova_2_0/nova_lite/SFT` and you should be able to see one recipe under this folder called: `nova_lite_2_0_p5x8_gpu_sft_with_datamix.yaml`
- Edite as seções na fórmula exigida pelo trabalho, como `name`, `data_s3_path`, `validation_s3_path`, `output_s3_path` e `max_steps`. Como estamos realizando o SFT, a noção de épocas não se aplica aqui.

A configuração da combinação de dados será a mesma, mas com uma seção extra de combinação de dados na parte inferior, semelhante a esta:

```
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

```

Há duas categorias de dados de alto nível aqui:

- nova_data: esta é a combinação real de dados e é subdividida em ainda mais categorias. É imperativo que eles totalizem até 100%
 - Uma análise completa dessas categorias, incluindo a contagem de tokens, pode ser encontrada abaixo
- customer_data: estes são seus dados de treinamento referenciados na chave data_s3_path na parte superior do seu YAML. A porcentagem fornecida aqui determina qual será a porcentagem resultante para nova_data. Por exemplo, nas seleções percentuais acima, durante o treinamento, usaremos 25% de customer_data e 75% de nova_data, dos quais 15% serão agentes, 15% serão negócios e finanças, 15% serão científicos, 15% serão códigos e 15% serão fatos e notícias

Dica: execute `pip install -e .` mais uma vez e tudo estará pronto para enviar sua tarefa.

Vamos substituir alguns parâmetros aqui para usar a combinação de dados:

```

hyperpod start-job \
-n kubeflow \
--recipe fine-tuning/nova/forged/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/
}'

```

Sua saída deve conter um nome de tarefa da seguinte forma:

```
# MY Desktop # % hyperpod start-job \
```

```
-n kubeflow \
--recipe training/nova/forged/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/
}'
```

A saída seria assim:

```
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"
```

```
}
```

Você pode ver o status da sua tarefa 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"
    }
  ]
}
```

ou use diretamente o comando `kubectl` para encontrá-los.

Por exemplo,

```
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>

Dica profissional: certifique-se de sempre usar o sinalizador `-o wide`, pois o nó do EKS em que o trabalho é executado ajudará você a encontrar seus logs ainda mais rapidamente na interface do usuário da AWS

Como monitorar a tarefa

Você pode visualizar seus logs de três maneiras:

a) Usando o CloudWatch

Seus logs estão disponíveis na sua conta da Amazon Web Services que contém o cluster do Hyperpod no CloudWatch. Para visualizá-los em seu navegador, navegue até a página inicial do CloudWatch em sua conta e pesquise o nome do seu cluster. Por exemplo, se seu cluster se chamasse `my-hyperpod-rig`, o grupo de logs teria o prefixo:

- Grupo de logs: `/aws/sagemaker/Clusters/my-hyperpod-rig/{UUID}`
- Quando estiver no grupo de logs, você poderá encontrar seu log específico usando o ID da instância do nó, como `- hyperpod-i-00b3d8a1bf25714e4`.
 - `i-00b3d8a1bf25714e4` aqui representa o nome da máquina compatível com o Hyperpod em que seu trabalho de treinamento está sendo executado. Lembre-se de como, na saída anterior do comando `kubectl get pods -o wide -w -n kubeflow | (head -n1 ; grep my-cpt-run)`, capturamos uma coluna chamada `NODE`.
 - Nesse caso, a execução do nó “principal” estava sendo executada em `hyperpod-i-00b3d8a1bf25714e4` e, portanto, usaremos essa string para selecionar o grupo de logs a ser visualizado. Selecione aquele que diz `SagemakerHyperPodTrainingJob/rig-group/[NODE]`

Seus logs devem ser semelhantes ao seguinte:

b) Usando o CloudWatch Insights

Se você souber o nome da sua tarefa e não quiser seguir todas as etapas acima, basta consultar todos os logs em `/aws/sagemaker/Clusters/my-hyperpod-rig/{UUID}` para encontrar o log individual.

CPT

```
fields @timestamp, @message, @logStream, @log
| filter @message like /(?!i)Starting CPT Job/
| sort @timestamp desc
```

```
| limit 100
```

Para a conclusão da tarefa, substitua Starting SFT Job por SFT Job completed

Em seguida, você pode clicar nos resultados e escolher aquele que diz “Epoch 0”, pois este será seu nó principal.

C) Usando a AWS CLI

Você pode optar por rastrear seus logs usando a CLI. Antes de fazer isso, verifique sua versão da AWS CLI usando `aws --version`. Também é recomendável usar esse script utilitário que ajuda no rastreamento de logs em tempo real em seu terminal.

para V1:

```
aws logs get-log-events \
  --log-group-name /aws/sagemaker/YourLogGroupName \
  --log-stream-name YourLogStream \
  --start-from-head | jq -r '.events[].message'
```

para V2:

```
aws logs tail /aws/sagemaker/YourLogGroupName \
  --log-stream-name YourLogStream \
  --since 10m \
  --follow
```

D) Configurando o MLflow:

Você pode acompanhar as métricas por meio do MLflow.

Criar uma aplicação MLflow

Usando a interface do usuário do Studio: se você criar uma tarefa de treinamento por meio da interface do usuário do Studio, uma aplicação MLflow padrão será criada automaticamente e estará selecionada por padrão em Opções avançadas.

Usando a CLI: se você usar a CLI, deverá criar uma aplicação MLflow e passá-la como uma entrada para a solicitação da API da tarefa de treinamento.

```
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)
```

Acessar a aplicação MLflow

Usando a CLI: crie um URL pré-assinado para acessar a interface do usuário da aplicação MLflow:

```
aws sagemaker create-presigned-mlflow-app-url \
  --arn $mlflow_app_arn \
  --region $region \
  --output text
```

Depois que o MLflow estiver configurado, você poderá passar o URI em sua fórmula ou usar a substituição ao iniciar o trabalho. Um exemplo de como fazer isso pode ser encontrado no README.

Como avaliar seu modelo após o SFT?

Pré-requisitos

- URI do ponto de verificação do S3 do arquivo manifest.json da sua tarefa de treinamento (para modelos treinados)
- Conjunto de dados de avaliação enviado para o S3 no formato correto
- Caminho do S3 de saída para os resultados da avaliação

Avaliações comparativas prontas para uso: use avaliações comparativas prontas para uso para validar a performance em tarefas gerais. Para obter mais detalhes, confira aqui.

Traga seus próprios dados:

Você também pode fornecer seus dados personalizados formatando-os no formato abaixo e, em seguida, usando os contêineres mencionados a seguir para obter resultados de inferência junto com probabilidades logarítmicas para calibrações, se necessário.

Crie um JSONL por tarefa com a seguinte estrutura:

```
{
  "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"
}
```

Os resultados gerados durante a fase de inferência da tarefa de avaliação terão a seguinte estrutura:

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

Descrições dos campos:

- prompt: entrada formatada enviada para o modelo
- inferência: resposta gerada pelo modelo
- gold: a resposta correta esperada do conjunto de dados de entrada, campo de resposta da entrada
- metadados: metadados opcionais transmitidos da entrada

Preparar a configuração da avaliação

Comando para iniciar a tarefa de avaliação. Use “--override-parameters” para modificar qualquer entrada da fórmula.

```
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"
  }'
```

Iniciar sua tarefa de avaliação

Comandos de inicialização de tarefas para diferentes fórmulas com imagens correspondentes.

Comandos de inicialização de tarefas de avaliação

Modelo	Técnica	Subcategory	URI da imagem	Command
Nova 2.0	Avaliação	Eval	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-HP-Eval-latest	hyperpod start-job -n kubeflow \ --recipe evaluation/nova/nova_micro_p5_48xl_bring_your_own_dataset_eval \ --override-parameters '{ "instance_type": "ml.p5.48xlarge", "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/

Modelo	Técnica	Subcategory	URI da imagem	Command
				nova-evaluation-repo:SM-HP-Eval-latest" }

Dicas e lições aprendidas

- A qualidade do conjunto de dados do SFT é fundamental. Você deve empenhar todos os esforços para filtrar dados de baixa qualidade. Se você tiver um pequeno subconjunto de dados de altíssima qualidade, em termos de complexidade e precisão, considere colocá-lo no final do treinamento para ajudar o modelo a convergir melhor.
- Utilizamos conjuntos de dados de texto e multimodais (MM) para combinação de dados. Nossos experimentos com conjuntos de dados de texto mostram que adicionar a categoria proprietária de “seguimento de instrução com raciocínio” do Nova melhora significativamente a performance em avaliações comparativas genéricas. Recomendamos incluir essa categoria em sua estratégia de combinação de dados se você se preocupa com a avaliação comparativa genérica que é regredida após a realização do SFT com seus conjuntos de dados.
- Para conjuntos de dados MM, nossos experimentos indicam que incorporar mais de 20% das categorias de vídeo à combinação é benéfico para manter a performance das avaliações comparativas genéricas.
- Além disso, o SFT com combinação de dados é bastante sensível à taxa de aprendizado, então nossa descoberta sugere um ajuste fino com a taxa de aprendizado padrão, ou seja, 1e-5 para LoRA e 5e-6 para FR.
- Finalmente, haverá um equilíbrio entre latência e performance se você combinar conjuntos de dados proprietários do Nova, então nossas descobertas sugerem combinar 50%, no máximo, para obter um bom equilíbrio.

Aprendizagem por reforço

Note

A documentação detalhada é fornecida após a inscrição

O Nova Forge fornece recursos avançados de aprendizado por reforço com a opção de usar funções remotas de recompensa em seu próprio ambiente. Os clientes podem optar por integrar seu próprio endpoint para executar a validação e obter feedback imediato no mundo real, ou também podem usar seu próprio orquestrador para coordenar avaliações agênticas de vários turnos em seu ambiente.

Traga seu próprio orquestrador para avaliações agênticas em vários turnos

Para usuários do Forge que precisam de conversas em vários turnos ou funções de recompensa que excedam o tempo limite de 15 minutos, o Nova Forge fornece recursos de traga sua própria orquestração (BYOO). Isso permite que você coordene avaliações agênticas de vários turnos em seu ambiente (por exemplo, usando ferramentas químicas para pontuar projetos moleculares ou simulações robóticas que recompensam a conclusão eficiente de tarefas e penalizam as colisões).

Tópicos

- [Visão geral da arquitetura](#)
- [Configuração e execução](#)

Visão geral da arquitetura

A arquitetura BYOO fornece controle total sobre o processo de distribuição e geração por meio da infraestrutura gerenciada pelo cliente.

Treinamento da VPC:

- Rollout: coordena o treinamento delegando a geração de distribuição à infraestrutura do cliente
- Trainer: realiza atualizações de peso do modelo com base nas distribuições recebidas

VPC do cliente (como ECS no EC2):

- Proxy Lambda: recebe solicitações de implantação e coordena com a infraestrutura do cliente
- Rollout Response SQS: enfileira para devolver distribuições concluídas à infraestrutura de treinamento
- Generate Request SQS: enfileira para solicitações de geração de modelo
- Generate Response SQS: enfileira para respostas de geração de modelos
- Contêiner do cliente: implementa a lógica de orquestração personalizada (pode usar o kit inicial fornecido)

- DynamoDB: armazena e recupera o estado em todo o processo de orquestração

Fluxo de trabalho:

1. O Rollout delega a geração da distribuição ao Proxy Lambda
2. O Proxy Lambda envia uma solicitação de distribuição da API para o Generate Request SQS
3. O contêiner do cliente processa as solicitações, gerencia as interações em vários turnos e chama funções de recompensa
4. O contêiner armazena e recupera o estado do DynamoDB, conforme necessário
5. O contêiner envia respostas de distribuição para o Rollout Response SQS
6. O Rollout envia distribuições concluídas ao Trainer para atualizações de peso

Configuração e execução

Para obter instruções detalhadas de configuração, configurações de fórmulas, formatos de solicitação e resposta e exemplos de ambiente, consulte a documentação confidencial fornecida aos assinantes do Nova Forge. Para obter os documentos do Nova Forge, siga as etapas abaixo:

```
aws s3 cp s3://nova-forge-c7363-206080352451-us-east-1/v1/ ./ --recursive
```

Depois que os ativos forem baixados, você poderá encontrar toda a documentação na pasta docs.

Kit de ferramentas de IA responsável e moderação de conteúdo

Kit de ferramentas de IA responsável

O Nova Forge fornece um kit de ferramentas de IA responsável que inclui dados de treinamento e avaliação para alinhar os modelos às diretrizes de IA responsável do Amazon Nova durante o processo de treinamento e controles de runtime para moderar as respostas do modelo durante a inferência.

Dados de treinamento: casos e cenários que enfatizam os princípios da IA responsável, considerações de segurança e implantação responsável de tecnologia estão disponíveis para a combinação de dados a fim de alinhar modelos de forma responsável durante o pré-treinamento contínuo.

Avaliações: as avaliações que testam a capacidade do modelo de detectar e rejeitar conteúdo impróprio, prejudicial ou incorreto estão disponíveis como uma tarefa de avaliação comparativa para determinar o delta entre a performance do modelo de base e a do modelo personalizado.

Controles de runtime: por padrão, o runtime do Amazon Nova controla as respostas moderadas dos modelos durante a inferência. Para modificar esses controles de runtime, solicite as configurações de moderação de conteúdo personalizáveis do Amazon Nova entrando em contato com um gerente de conta da AWS.

A segurança é uma responsabilidade compartilhada entre a AWS e seus usuários. Alterar o modelo de base ou usar o pré-treinamento contínuo para melhorar a performance em um caso de uso específico pode afetar a segurança, a imparcialidade e outras propriedades do novo modelo. Um método de adaptação robusto minimiza as alterações na segurança, na imparcialidade e em outras proteções incorporadas aos modelos de base, ao mesmo tempo em que minimiza o impacto na performance do modelo em tarefas para as quais o modelo não foi personalizado. É necessário testar as aplicações de ponta a ponta em conjuntos de dados representativos de casos de uso para determinar se os resultados dos testes atendem às expectativas específicas de segurança, imparcialidade e outras propriedades, bem como à eficácia geral. Para obter mais informações, consulte o Guia de uso responsável da IA da Amazon Web Services, a Política de IA responsável da Amazon Web Services, a Política de uso aceitável da Amazon Web Services e os Termos de serviço da Amazon Web Services.

Uso responsável

Criar medidas de segurança, proteção e confiança com modelos de IA é uma responsabilidade compartilhada entre a AWS e nossos clientes. Nosso objetivo é alinhar nossos modelos à [Política de Uso Aceitável da AWS](#) e mitigar resultados indesejados e, ao mesmo tempo, proporcionar uma experiência agradável ao cliente. Nossa abordagem à IA responsável (RAI) é estruturada em torno de nossas [dimensões centrais de IA responsável](#), que serão abordadas na lista a seguir. Para cada uma dessas dimensões, desenvolvemos diretrizes que regem nossa tomada de decisão durante todo o ciclo de vida do desenvolvimento do modelo. Esse ciclo de vida abrange todas as etapas, desde a coleta inicial de dados e o pré-treinamento até a implementação de mitigações de runtime pós-implantação.

- Equidade: considerar os impactos nos diferentes grupos de partes interessadas
- Explicabilidade: compreender e avaliar as saídas do sistema
- Privacidade e segurança: obter, usar e proteger dados e modelos de forma adequada
- Segurança: prevenir saídas prejudiciais e uso indevido
- Controlabilidade: ter mecanismos para monitorar e direcionar o comportamento do sistema de IA
- Veracidade e robustez: obter saídas corretas do sistema, mesmo com entradas inesperadas ou contraditórias
- Governança: incorporar as práticas recomendadas na cadeia de suprimentos de IA, incluindo provedores e implementadores
- Transparência: permitir que as partes interessadas façam escolhas informadas sobre o comprometimento deles com um sistema de IA

Diretrizes

As diretrizes que usamos para direcionar o desenvolvimento de nosso modelo incluem, entre outras, a moderação de conteúdo que exalta, facilita ou promove o seguinte:

- Participação em atividades perigosas, automutilação ou uso de substâncias perigosas.
- Uso, uso indevido ou comércio de substâncias controladas, tabaco ou álcool.
- Violência física ou crueldade.
- Abuso infantil ou material de abuso sexual infantil.
- Abuso ou tráfico de animais.

- Desinformação que posiciona indivíduos ou grupos como responsáveis por fraude deliberada, minando uma instituição com credibilidade pública geral ou colocando em risco a saúde ou a subsistência humana.
- Malware, conteúdo malicioso ou qualquer conteúdo que facilite o crime cibernético.
- Desrespeito, discriminação ou estereótipo em relação a um indivíduo ou grupo.
- Insultos, profanidade, gestos obscenos, linguagem sexualmente explícita, pornografia, símbolos de ódio ou grupos de ódio.
- Nudez total que esteja fora de um contexto científico, educacional ou de referência.
- Preconceito contra um grupo com base em uma característica demográfica.

Recomendações

Adequação para uso: como as saídas do modelo de IA são probabilísticas, o Amazon Nova pode produzir conteúdo impreciso ou inadequado. Os clientes devem avaliar as saídas quanto à precisão e adequação ao seu caso de uso, especialmente se elas forem apresentadas diretamente aos usuários finais. Além disso, se o Amazon Nova for usado em fluxos de trabalho de clientes que geram decisões consequentes, os clientes devem avaliar os riscos potenciais de seu caso de uso e implementar supervisão humana adequada, testes e outras proteções específicas do caso de uso para mitigar tais riscos.

Otimizações de prompt: no caso de encontrar moderação por parte do Amazon Nova, considere examinar os prompts usados com relação às diretrizes acima. Otimizar os prompts para reduzir a probabilidade de gerar resultados indesejados é a estratégia recomendada para produzir os resultados esperados usando os modelos do Amazon Nova. Preste atenção onde a entrada é controlada pelos usuários, incluindo o conteúdo de pixels que pode afetar a performance do modelo. Consulte a seção de diretrizes de prompts neste guia do usuário para obter mais detalhes.

Privacidade: o Amazon Nova está disponível no Amazon Bedrock. O Amazon Bedrock é um serviço gerenciado e não armazena nem analisa os prompts ou as conclusões de prompts dos clientes, e os prompts e as conclusões nunca são compartilhados entre clientes ou com parceiros do Amazon Bedrock. A AWS não usa entradas ou saídas geradas por meio do serviço do Amazon Bedrock para treinar modelos do Amazon Bedrock, incluindo o Amazon Nova. Consulte a Seção [50.3](#) dos Termos de Serviço da AWS e as [Perguntas frequentes sobre privacidade de dados](#) da AWS para obter mais informações. Para obter informações de privacidade específicas do serviço, consulte a seção Privacidade e Segurança da documentação de [Perguntas frequentes do Amazon Bedrock](#). O Amazon Nova toma medidas para evitar o preenchimento de prompts que possam ser interpretados

como solicitação de informações privadas. Se um usuário estiver preocupado com o fato de suas informações privadas terem sido incluídas em um preenchimento do Amazon Nova, ele deverá entrar em contato conosco [aqui](#).

Segurança: todos os modelos do Amazon Bedrock, incluindo o Amazon Nova, vêm com segurança corporativa que permite aos clientes criar aplicações de IA generativa compatíveis com padrões comuns de segurança e conformidade de dados, incluindo GDPR e HIPAA. Os clientes podem usar o AWS PrivateLink para estabelecer conectividade privada entre o Amazon Nova personalizado e redes on-premises sem expor o tráfego do cliente à internet. Os dados dos clientes são sempre criptografados em trânsito e em repouso, e eles podem usar suas próprias chaves para criptografar os dados, por exemplo, usando o AWS Key Management Service. Os clientes podem usar o AWS Identity and Access Management para controlar com segurança o acesso aos recursos do Amazon Bedrock, incluindo o Amazon Nova personalizado. Além disso, o Amazon Bedrock oferece recursos abrangentes de monitoramento e registro em log que podem reforçar os requisitos de governança e auditoria do cliente. Por exemplo, o Amazon CloudWatch pode ajudar a rastrear as métricas de uso necessárias para fins de auditoria, e o AWS CloudTrail pode ajudar a monitorar a atividade da API e solucionar problemas à medida que o Amazon Nova é integrado a outros sistemas da AWS. Os clientes também podem optar por armazenar os metadados, os prompts e as conclusões em seu próprio bucket criptografado do Amazon Simple Storage Service (Amazon S3).

Propriedade intelectual: A AWS oferece cobertura ilimitada de indenização de propriedade intelectual (PI) para as saídas dos modelos disponíveis para o público em geral do Amazon Nova (consulte a Seção 50.10 dos [Termos de Serviço](#)). Isso significa que os clientes estão protegidos contra reclamações de terceiros alegando violação de PI ou apropriação indébita (incluindo reivindicações de direitos autorais) pelas saídas geradas por esses modelos do Amazon Nova. Além disso, nossa indenização padrão de PI pelo uso dos serviços protege os clientes de reivindicações de terceiros alegando violação de PI (incluindo reivindicações de direitos autorais) pelos serviços (incluindo modelos do Amazon Nova) e pelos dados usados para treiná-los.

Cotas do Amazon Nova

Sua Conta da AWS tem cotas padrão, anteriormente chamadas de limites, para o Amazon Bedrock. Para visualizar as cotas de serviço do Amazon Bedrock, execute um dos seguintes procedimentos:

- Siga as etapas em [Visualizar cotas de serviço](#) e selecione Amazon Bedrock como o serviço.
- Consulte [Amazon Bedrock endpoints and quotas](#) no Referência geral da AWS.

Note

Se uma cota estiver marcada como não ajustável por meio do Service Quotas, você poderá enviar uma solicitação usando o [formulário de aumento de limite](#) para que ela seja analisada.

Para manter a performance do serviço e garantir o uso adequado do Amazon Bedrock, as cotas padrão atribuídas a uma conta podem ser atualizadas dependendo de fatores regionais, histórico de pagamentos, uso fraudulento e/ou aprovação de uma solicitação de aumento de cota.

Solicitar um aumento das cotas do Amazon Nova

É possível solicitar um aumento de cotas para sua conta seguindo as etapas abaixo:

- Se uma cota estiver marcada como Yes na coluna Ajustável em [Amazon Bedrock endpoints and quotas](#) no Referência geral da AWS, você poderá ajustá-la seguindo as etapas em [Requesting a Quota Increase](#) no [Guia do usuário do Service Quotas](#).
- As cotas de invocação de modelo sob demanda em [Amazon Bedrock endpoints and quotas](#) no Referência geral da AWS não são ajustáveis por meio do Service Quotas. Entre em contato com o gerente da Conta da AWS para ver a possibilidade de um aumento.

Note

Devido à extraordinária demanda, a prioridade será dada aos clientes que geram tráfego que consome sua alocação de cota existente. Sua solicitação poderá ser negada se você não atender a essa condição.

- É possível enviar uma solicitação por meio do [formulário de aumento de limite](#) para ver a possibilidade de um aumento, mesmo que uma cota esteja marcada como No na coluna Ajustável em [Amazon Bedrock endpoints and quotas](#) no Referência geral da AWS.

Monitorar o Amazon Nova

O monitoramento é uma parte importante para manter a confiabilidade, a disponibilidade e o desempenho do Amazon Nova e das outras soluções da AWS. A AWS fornece as seguintes ferramentas de monitoramento para observar o Amazon Nova, informar quando algo está errado e executar ações automaticamente quando apropriado:

Como o Amazon Nova está disponível por meio do Amazon Bedrock, siga todas as orientações de monitoramento em [Monitor the health and performance of Amazon Bedrock](#).

Segurança no Amazon Nova

A segurança da nuvem na AWS é a nossa maior prioridade. Como cliente da AWS, você se beneficiará de data centers e arquiteturas de rede criados para atender aos requisitos das empresas com as maiores exigências de segurança.

A segurança é uma responsabilidade compartilhada entre a AWS e você. O [Modelo de Responsabilidade Compartilhada](#) descreve isso como segurança da nuvem e segurança na nuvem:

- Segurança da nuvem: a AWS é responsável pela proteção da infraestrutura que executa os serviços da AWS na Nuvem AWS. A AWS também fornece serviços que podem ser usados com segurança. Auditores terceirizados testam e verificam regularmente a eficácia da nossa segurança como parte dos [Programas de conformidade da AWS](#). Para saber mais sobre os programas de conformidade que se aplicam ao Amazon Nova, consulte [Serviços da AWS no escopo pelo programa de conformidade](#).
- Segurança na nuvem: sua responsabilidade é determinada pelo serviço da AWS que você usa. Você também é responsável por outros fatores, incluindo a confidencialidade de seus dados, os requisitos da empresa e as leis e regulamentos aplicáveis.

Como o Amazon Nova está disponível por meio do Amazon Bedrock, siga todas as orientações de segurança em [Segurança no Amazon Bedrock](#).

Criar recursos do Amazon Nova com o AWS CloudFormation

Ao implantar modelos do Amazon Nova por meio do Amazon Bedrock com o CloudFormation, siga todas as orientações do CloudFormation em [Criar recursos do Amazon Bedrock com o CloudFormation](#).

Para obter mais informações, incluindo exemplos de modelos JSON e YAML para YOUR-RESOURCE-PLURAL, consulte [YOUR-SERVICE-RESOURCE-TOPNODE-IN-CLOUDFORMATION, modifique este link no arquivo local-phrases.ent](#) no Guia do usuário do AWS CloudFormation.

Saiba mais sobre o CloudFormation

Para saber mais sobre o CloudFormation, consulte os seguintes recursos:

- [AWS CloudFormation](#)
- [AWS CloudFormation Guia do usuário do](#)
- [CloudFormation Referência de API do](#)
- [AWS CloudFormation Guia do Usuário da Interface de Linha de Comando](#)

Histórico do documento do Guia do desenvolvedor do Amazon Nova

A tabela a seguir descreve as versões da documentação do Amazon Nova 2.0.

Alteração	Descrição	Data
Versão inicial do Amazon Nova 2.0	Versão inicial do Guia do desenvolvedor do Amazon Nova 2.0 com novos modelos: Nova 2 Lite, Amazon Nova Sonic e . Este guia apresenta recursos multimodais aprimorados, recursos de raciocínio e desempenho aprimorado em todas as camadas do modelo.	2 de dezembro de 2025