



Guía para desarrolladores de Amazon Nova 2

Amazon Nova



Amazon Nova: Guía para desarrolladores de Amazon Nova 2

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

Las marcas comerciales y la imagen comercial de Amazon no se pueden utilizar en relación con ningún producto o servicio que no sea de Amazon, de ninguna manera que pueda causar confusión entre los clientes y que menosprecie o desacredite a Amazon. Todas las demás marcas registradas que no son propiedad de Amazon, sino que son propiedad de sus respectivos propietarios, que pueden o no estar afiliados, conectados o patrocinados por Amazon.

Table of Contents

¿Qué es Amazon Nova 2?	1
Conceptos clave	1
Modelos de Amazon Nova	1
¿Qué puede crear?	2
Ventajas	3
Cómo funciona Amazon Nova	3
Precios	4
Sigüientes pasos	4
Novedades de Amazon Nova 2	5
Modelos nuevos	5
Nuevas características y capacidades	5
Nova Multimodal Embeddings	5
Pensamiento extendido y razonamiento	5
Herramientas integradas	6
Creación de agentes de IA	6
Comprensión de documentos mejorada	6
Comprensión de videos mejorada	6
Personalización de modelos	6
Amazon Nova Forge	7
Sigüientes pasos	7
Introducción	8
Introducción a la consola	8
Exploración del área de juegos de texto	9
Introducción a la API	9
Obtención de credenciales para conceder acceso programático	11
Cómo adjuntar permisos de Amazon Bedrock a un usuario o rol	13
Generación de una respuesta para una petición de texto mediante un modelo de Amazon Nova	13
Inferencia básica	15
Importante: Configuración del tiempo de espera	16
Temas de inferencia básica	16
Uso de la API de Converse	17
Estructura de la solicitud	17
Uso de peticiones del sistema	18

Parámetros de inferencia	19
Uso del razonamiento	20
Uso de la API de Invoke	23
Estructura de la solicitud	23
Parámetros de solicitud	24
Respuestas de transmisión	24
Transmisión con ConverseStream	24
Transmisión con InvokeModelWithResponseStream	25
Tipos de eventos de transmisión	25
Uso de incrustaciones de Amazon Nova	26
Características principales de	26
Generación de incrustaciones	27
Inferencia bajo demanda	31
Ventajas	31
Uso de la inferencia bajo demanda	31
Precios	32
Cuotas y límites	32
Uso de las capacidades de Nova	33
Razonamiento	33
Comprensión multimodal	34
Tipo de contenido compatible por modalidad	34
Comprensión de imágenes	35
Comprensión de videos	38
Comprensión de documentos	41
Voz a voz	43
Características principales de	43
Introducción	44
Establecimiento de las importaciones y la configuración	44
Definición de la clase SimpleNovaSonic	45
Inicialización del cliente	46
Gestión de eventos	46
Inicio de sesión	47
Gestión de la entrada de audio	49
Finalización de la sesión	51
Tratamiento de respuestas	52
Reproducción de audio	53

Captura de audio	54
Ejecución de la función principal	55
Ejemplos de código	56
Ejemplos sobre cómo comenzar	56
Casos de uso avanzados	57
Taller práctico	58
Peticiones de conversación de voz	58
Directrices importantes	59
Petición del sistema de línea de base recomendada para voz	59
Configuración de peticiones de voz	59
Configuración de peticiones del sistema	60
Concordancia de género para idiomas con géneros	61
Cadena de pensamiento para el habla: razonamiento constitutivo	62
Uso excesivo de frases sugeridas	63
Conceptos clave	65
Ciclo de vida de eventos	65
Secuencia de flujos de eventos	67
Gestión de eventos de entrada con la API bidireccional	67
Gestión de eventos de salida con la API bidireccional	76
Barge-in (Interrumpir)	83
Control de los turnos	85
Entrada multimodal	86
Soporte lingüístico y capacidades multilingües	89
Administración del historial del chat	91
Configuración de herramientas	96
Llamadas a herramientas asíncronas	104
Integraciones	107
Strands Agents	107
Integraciones con marcos	110
Sistemas avanzados con Nova	121
Descripción general	121
Pensamiento extendido	121
Cómo funciona el pensamiento extendido	121
Opciones de configuración	124
Modelos compatibles	125
Pensamiento extendido con el uso de herramientas	125

Descripción de los tokens de razonamiento y los precios	125
Preguntas frecuentes	126
Uso de herramienta	127
Descripción del flujo de trabajo del uso de herramientas	127
Creación de una herramienta	128
Llamada a una herramienta	131
Herramientas del sistema integradas	134
Creación de agentes de IA	137
Creación de un agente	137
Invocación de un agente	139
Web Grounding	142
Cómo funciona Web Grounding	142
Cómo utilizar Web Grounding	143
Disponibilidad en las regiones	144
Estructura de una respuesta	144
Seguridad del anclaje	145
Gestión de errores	145
Permisos obligatorios para herramientas integradas	145
Ingeniería de peticiones	147
¿Qué es la ingeniería de peticiones?	147
Introducción a la ingeniería de peticiones	147
Prácticas recomendadas	148
Descripción de los roles	148
Creación de peticiones precisas	149
Enfoque a secciones de la petición	168
Uso del rol del sistema	169
Cómo proporcionar ejemplos (petición con pocos pasos)	178
Sistemas de llamadas a herramientas	188
Técnicas de peticiones avanzadas	189
Peticiones de entradas multimodales	211
Directrices multimodales generales	211
Comprensión de documentos e imágenes	212
Comprensión de videos	38
Moderación de contenido	224
Principios clave	225
Configuración recomendada	225

Taxonomía universal de MLCommons	225
Ejemplos de peticiones	227
Código y solución de problemas	233
Biblioteca de códigos	233
Ejemplos de la API de Converse	233
Ejemplos de API InvokeModel	253
Solución de problemas	258
Autenticación y configuración	258
Acceso denegado al modelo	259
Problemas de disponibilidad regional	259
Configuración de tiempo de espera	259
Problemas de respuesta de API	260
Errores del modo de razonamiento	261
Problemas del uso de herramientas	262
Referencia de API y SDK	266
Esquema de la solicitud y de la respuesta	266
Estructura de la solicitud completa	266
Estructura de la respuesta completa	271
Referencia del SDK	274
Personalización de los modelos de Amazon Nova	276
Enfoques de personalización	276
Plataformas de personalización	277
Requisitos previos generales	278
Fórmulas de Amazon Nova	279
Obtención de fórmulas básicas	280
Obtención de fórmulas de Forge	281
Modelos y algoritmos disponibles	281
Amazon Nova 2.0 Lite	282
En trabajos de entrenamiento de SageMaker	289
Prácticas recomendadas para la personalización de Amazon Nova	290
SDK de Nova Forge	295
Formación	302
Supervisión del progreso en las iteraciones	344
Evaluación	349
Entrenamiento iterativo	417
En SageMaker HyperPod	418

Requisitos de computación de los modelos de Amazon Nova 2	418
Prácticas recomendadas para la personalización de Amazon Nova	290
SDK de Nova Forge	425
Configuración del clúster de HP	426
Guía de comandos esenciales	426
Acceso a Nova Forge y configuración	436
Formación	438
Evaluación	480
Supervisión con MLflow	533
Entrenamiento iterativo	535
Descripción general	535
Funcionamiento	536
Cuándo utilizar el entrenamiento iterativo	537
Ejemplo de flujo de trabajo: SFT → RFT	539
Supervisión del progreso en las iteraciones	540
Prácticas recomendadas	543
Consideraciones sobre costos	545
Limitaciones	545
Solución de problemas	547
Inferencias de SageMaker	548
Características	549
Modelos e instancias compatibles	550
Regiones de AWS compatibles	553
Imágenes de contenedor compatibles	553
Prácticas recomendadas	553
Soporte	554
Introducción	554
Referencia de la API	576
Evaluación de los modelos	585
Detección de abusos para Amazon Nova Forge	592
Inferencia de Amazon Bedrock	593
Implementar un modelo personalizado para inferencia bajo demanda	594
Inferencia bajo demanda	600
Limitaciones	602
Nova Forge	604
Requisitos previos	604

Suscripción a Nova Forge	604
Otros requisitos previos	605
Acceso a Nova Forge y configuración	605
Obtención de los documentos de Nova Forge	605
Paso 1: suscripción a Nova Forge	605
Paso 2. Configuración de la infraestructura de HyperPod	612
Configuración de moderación de contenido	612
Entrenamiento previo continuo y entrenamiento intermedio	613
¿Qué son los puntos de control intermedios y por qué son necesarios?	613
¿Qué puntos de control hay disponibles?	614
¿Qué punto de control usar?	615
¿Cómo se utiliza la mezcla de datos para Nova 2.0?	616
Análisis de las categorías de mezcla de datos	618
Refinamiento supervisado	623
Introducción	623
¿Cuándo se debe usar SFT?	623
¿Cuándo usar un SFT que haga un uso eficiente de los parámetros y cuándo usar un SFT de rango completo?	624
Mezcla de datos para el SFT	624
Ejemplos de configuración de YAML	625
Puntos de control del modelo	627
Estrategias de entrenamiento	628
Requisitos previos antes de empezar	629
Un enfoque sistemático para lograr un SFT exitoso	630
Experimentación con el orden y la mezcla de datos	630
Preparación del conjunto de datos para el SFT	631
Métodos de evaluación	632
Prácticas recomendadas	290
Configuración de la preparación de trabajos de entrenamiento	634
Configuración del bloque de mezcla de datos	636
¿Cómo lanzar un trabajo?	642
Cómo supervisar un trabajo	651
¿Cómo evaluar su modelo después del SFT?	653
Lecciones aprendidas y consejos	656
Aprendizaje por refuerzo	657
Uso de su propio orquestador para las evaluaciones de los agentes de varios turnos	657

Kit de herramientas de IA responsable	659
Kit de herramientas de IA responsable	659
Uso responsable	660
Directrices	660
Recomendaciones	661
Cuotas	663
Solicitud de un aumento de las cuotas de Amazon Nova	663
Supervisión	665
Seguridad	666
Creación de recursos con CloudFormation	667
Obtención de más información sobre CloudFormation	667
Historial de revisión	668

¿Qué es Amazon Nova 2?

Amazon Nova proporciona modelos fundacionales multimodales que procesan texto, imágenes, video, documentos y voz. Con soporte para hasta 1 millón de tokens de contexto y capacidades de razonamiento avanzadas, los modelos de Amazon Nova 2 le permiten crear aplicaciones de IA sofisticadas que comprenden entradas complejas y generan respuestas precisas.

Puede crear chatbots interactivos, analizar documentos y videos, crear agentes de IA con un razonamiento extendido y desarrollar aplicaciones con voz.

Conceptos clave

Antes de obtener información sobre los modelos de Amazon Nova, familiarícese con los siguientes conceptos básicos:

Modelos fundacionales

Sistemas de IA entrenados previamente disponibles en diferentes tamaños y capacidades a los que puede acceder a través de una API.

Inferencia

Proceso de enviar una solicitud a un modelo y recibir una respuesta generada.

Razonamiento

Capacidad de pensamiento extendido que permite a los modelos desglosar problemas complejos y mostrar su análisis paso a paso antes de proporcionar respuestas.

Multimodal

Capacidad de procesar y comprender varios tipos de entradas a la vez: texto, imágenes, video y documentos en una sola solicitud.

RAG (generación aumentada por recuperación)

Técnica que combina respuestas del modelo con sus propios orígenes de datos para ofrecer respuestas contextuales más precisas.

Modelos de Amazon Nova

Amazon Nova 2 incluye los siguientes modelos, cada uno optimizado para distintos casos de uso:

Modelo	Modalidades de entrada	Modalidades de salida	Casos de uso
Nova 2 Lite	Texto, imágenes, video y documentos	Texto	Aplicaciones de gran volumen que priorizan la velocidad y la rentabilidad
Nova 2 Sonic	Voz, texto	Voz, texto	Aplicaciones con voz con tiempos de respuesta rápidos
Nova Multimodal Embeddings	Texto, imágenes, documentos, video y audio	Incrustaciones	Búsqueda semántica , sistemas de recomendación y búsqueda de similitudes

Todos los modelos admiten hasta 1 millón de tokens de contexto y pueden generar hasta 65 536 tokens en una sola respuesta. Los modelos con capacidades de razonamiento pueden llevar a cabo el pensamiento extendido para resolver problemas complejos paso a paso.

¿Qué puede crear?

A continuación se muestran ejemplos de lo que puede crear con Amazon Nova:

- Asistente de documentos inteligente: procese documentos de gran tamaño con hasta 1 millón de tokens de contexto para responder a preguntas y extraer información (con RAG).
- Aplicaciones de razonamiento complejo: resuelva problemas de varios pasos con un pensamiento extendido que muestre el análisis paso a paso del modelo (o con un razonamiento).
- Canalización de análisis de video: extraiga información, genere resúmenes e identifique momentos clave del contenido de video a escala (Nova 2 Lite).
- Agente de IA con voz: cree agentes conversacionales que entiendan la entrada de voz y respondan con un lenguaje natural (Nova 2 Sonic).

Ventajas

Amazon Nova ofrece las siguientes ventajas:

Comprensión multimodal

Procese texto, imágenes, video, documentos y voz en una sola solicitud. Los modelos de Amazon Nova comprenden las relaciones entre los distintos tipos de entrada.

Contexto ampliado

El soporte para hasta 1 millón de tokens le permite procesar bases de código completas, documentos extensos o conversaciones prolongadas sin perder el contexto.

Razonamiento avanzado

Los modelos con capacidad de razonamiento desglosan problemas complejos y muestran un análisis paso a paso, lo que mejora la precisión de las tareas de varios pasos.

Implementación flexible

Acceda a los modelos a través de Amazon Bedrock sin necesidad de administrar ninguna infraestructura o personalice los modelos mediante refinamiento y aprendizaje por refuerzo.

Herramientas integradas

Utilice el Anclaje web para acceder a información en tiempo real y Code Interpreter para ejecutar código Python sin integraciones externas.

Cómo funciona Amazon Nova

Los modelos de Amazon Nova son modelos fundacionales a los que puede acceder a través de Amazon Bedrock. El flujo de trabajo básico es:

1. La aplicación envía una solicitud a Amazon Bedrock con los parámetros de entrada y configuración.
2. El modelo de Amazon Nova procesa la entrada y aplica el razonamiento si está configurado.
3. El modelo genera una respuesta y la devuelve a la aplicación.

Puede mejorar las respuestas con la RAG para incorporar datos, habilitar las herramientas integradas o personalizar los modelos mediante refinamiento.

Precios

Los precios de Amazon Nova se basan en los tokens de entrada y salida procesados. Los diferentes modelos tienen diferentes niveles de precios:

- Nova 2 Lite: optimizado para un procesamiento rentable y de gran volumen
- Nova 2 Sonic: precios equilibrados para aplicaciones con voz

Para obtener información actual acerca de los precios, consulte [Precios de Amazon Bedrock](#).

Siguientes pasos

- Para obtener más información acerca de las nuevas características de Amazon Nova 2, consulte [Novedades de Amazon Nova 2](#).
- Para comenzar a usar Amazon Nova, consulte [Introducción a Amazon Nova 2](#).
- Para obtener información acerca de las capacidades de inferencia básicas, consulte [Inferencia básica](#).
- Para personalizar los modelos para el caso de uso, consulte [Personalización de los modelos de Amazon Nova en SageMaker AI](#).

Novedades de Amazon Nova 2

Amazon Nova 2 presenta mejoras significativas en las capacidades de comprensión, creatividad y voz. En las siguientes secciones, se describen las nuevas características y mejoras clave.

Modelos nuevos

Nova 2 Lite

Modelos mejorados que ofrecen un razonamiento avanzado compatible con el pensamiento extendido, un control de intensidad de tres niveles y una comprensión multimodal optimizados para flujos de trabajo agénticos a escala de producción.

Nova 2 Sonic

Modelo de voz conversacional actualizado con capacidades mejoradas de comprensión del habla, procesamiento del lenguaje natural y generación de voz en siete idiomas.

Nova Multimodal Embeddings

Modelo de incrustación multimodal que procesa entradas de texto, imágenes, documentos, video y audio y genera incrustaciones.

Nuevas características y capacidades

Nova Multimodal Embeddings

Nova Multimodal Embeddings admite texto, documentos, imágenes, video y audio en un único modelo, lo que permite aplicaciones de recuperación intermodal. Nova Multimodal Embeddings asigna cada uno de estos tipos de contenido en un espacio semántico unificado, lo que le permite llevar a cabo operaciones vectoriales unimodales, intermodales y multimodales, lo que impulsa aplicaciones como la generación aumentada por recuperación (RAG) agéntica y la búsqueda semántica multimodal.

Pensamiento extendido y razonamiento

Nova 2 Lite admite el pensamiento extendido, lo que permite a los modelos dedicar más tiempo al razonamiento de problemas complejos antes de generar respuestas. Esta capacidad mejora la precisión de las tareas de razonamiento de varios pasos, lo que incluye los flujos de trabajo

agénticos con varias herramientas, las matemáticas avanzadas, la planificación compleja y la generación de código.

Para obtener más información, vaya a [Pensamiento extendido en Amazon Nova 2](#).

Herramientas integradas

Amazon Nova 2 incluye herramientas integradas que amplían las capacidades del modelo sin necesidad de integraciones externas:

- Anclaje web: accede a información de Internet en tiempo real para ofrecer respuestas actualizadas y reducir las alucinaciones.
- Code Interpreter: ejecuta código de Python para efectuar cálculos.

Creación de agentes de IA

Los modelos de Amazon Nova 2 están optimizados para crear agentes de IA. Los modelos proporcionan un mejor uso de las herramientas, un mejor razonamiento para las tareas de varios pasos y una capacidad mejorada para mantener el contexto en los flujos de trabajo complejos de los agentes.

Comprensión de documentos mejorada

Nova 2 Lite proporciona capacidades mejoradas de procesamiento de documentos con una mejor comprensión de diseños, tablas, gráficos y documentos de varias páginas en documentos complejos. Los modelos extraen información con mayor precisión de archivos PDF, hojas de cálculo y otros formatos de documentos.

Comprensión de videos mejorada

Nova 2 Lite ofrece capacidades de análisis de video mejoradas, que incluyen una mejor percepción visual, comprensión temporal, reconocimiento de acciones y la capacidad de procesar secuencias de video más largas con mayor precisión.

Personalización de modelos

Nova 2 Lite admite el refinamiento supervisado (SFT) y el refinamiento por refuerzo (RFT) en Amazon Bedrock y SageMaker AI, lo que le permite adaptar Amazon Nova 2 a sus necesidades empresariales específicas.

Amazon Nova Forge

Amazon Nova Forge es un servicio pionero que ofrece a las organizaciones la forma más fácil y rentable de crear sus propios modelos de frontera con Amazon Nova.

Siguientes pasos

- Para obtener más información sobre los modelos y las capacidades de Amazon Nova, consulte [¿Qué es Amazon Nova 2?](#).
- Para comenzar a usar Amazon Nova 2.0, consulte [Introducción a Amazon Nova 2](#).
- Para explorar las principales características de inferencia, consulte [Inferencia básica](#).

Introducción a Amazon Nova 2

Puede invocar modelos de Amazon Nova 2 a través de los siguientes métodos:

- Operaciones de la API [InvokeModel](#) o de [Converse](#) de Amazon Bedrock
- [Área de pruebas de chat y texto](#) de Amazon Bedrock para Nova 2 Lite y Nova 2 Sonic

Important

Si es la primera vez que utiliza AWS o Amazon Bedrock, primero debe configurar Amazon Bedrock siguiendo los pasos que se indican en [Introducción a Amazon Bedrock](#). Como alternativa, puede probar los modelos de Amazon Nova sin ingresar en Amazon Bedrock en nova.amazon.com o comenzar a crear de forma gratuita en nova.amazon.com/dev.

Seleccione un tema para empezar a usar Amazon Nova con ese método.

Introducción a Amazon Nova en la consola de Amazon Bedrock

En esta sección, se describe cómo utilizar las áreas de pruebas de la consola de AWS para enviar una petición de texto a los modelos de Amazon Nova 2 y generar una respuesta de texto o imagen. Antes de ejecutar los siguientes ejemplos, debe comprobar que cumple los requisitos previos que se indican a continuación:

Requisitos previos

- Tiene una cuenta de AWS y permisos para acceder a un rol de esta cuenta con los permisos necesarios para Amazon Bedrock. De lo contrario, siga los pasos en [Introducción a Amazon Bedrock](#).
- Si accede al modelo desde una región de EE. UU., debe utilizar el punto de conexión CRIS estadounidense, que implica agregar el prefijo us al ID del modelo (por ejemplo, `us.amazon.nova-2-lite-v1:0`).
- Si accede al modelo desde fuera de EE. UU., puede utilizar el punto de conexión de CRIS global (por ejemplo, `global.amazon.nova-2-lite-v1:0`) o aplicar el prefijo de la región en el ID del modelo (por ejemplo, `us`, `eu` o `jp`).

Exploración del área de juegos de texto

El siguiente ejemplo muestra cómo usar el área de juegos de texto:

1. Abra la consola de Amazon Bedrock en <https://console.aws.amazon.com/bedrock/>.
2. En el panel de navegación de la izquierda, elija Chat/Texto en Áreas de juegos.
3. Elija Seleccionar modelo. A continuación, seleccione un proveedor y un modelo. Para este ejemplo, seleccione Amazon y, a continuación, seleccione un modelo de Amazon Nova 2 (como Nova 2 Lite o Nova 2 Sonic). A continuación, elija Aplicar.
4. Seleccione una petición predeterminada debajo del panel de texto o introduzca una petición en el panel de texto, como **Describe the purpose of a "hello world" program in one line.**
5. Para explorar las capacidades de comprensión de imágenes de Amazon Nova, puede cargar una imagen en formato JPEG, PNG, GIF o WEBP que tenga un tamaño inferior o igual a 25 MB desde su computadora. Una vez cargada, puede preguntarle a Amazon Nova acerca de la imagen.
6. Para explorar las capacidades de comprensión de documentos de Amazon Nova, puede cargar un documento en formato CSV, DOC, DOCX, HTML, MD, PDF, TXT, XLS o XLSX con un tamaño inferior o igual a 4,5 MB. Una vez cargados, puede preguntarle a Amazon Nova acerca de los documentos.
7. Para explorar las capacidades de comprensión de video de Amazon Nova, puede cargar un video en formato MKV, MOV o MP4 de un tamaño inferior o igual a 25 MB desde su computadora. Puede utilizar Amazon S3 para videos de hasta 1 GB. Una vez cargado, puede preguntarle a Amazon Nova acerca del video.
8. Seleccione Ejecutar para ejecutar la inferencia en el modelo. El texto generado aparece debajo de la petición en el panel de texto.

Introducción a la API

Antes de comenzar con las API, siga estos procedimientos si es la primera vez que utiliza AWS o necesita instalar la AWS CLI o un AWS SDK. Si ninguna de estas opciones se aplica a su caso, pase a [Obtención de credenciales para conceder acceso programático](#).

Es la primera vez que utilizo AWS

Si no dispone de una cuenta de AWS, siga los pasos que figuran a continuación para crear una. Como alternativa, puede comenzar a crear de forma gratuita con Amazon Nova en nova.amazon.com/dev.

Registro en una cuenta de AWS

1. Abra <https://portal.aws.amazon.com/billing/signup>.
2. Siga las instrucciones que se le indiquen.

Parte del procedimiento de registro consiste en recibir una llamada telefónica o mensaje de texto e indicar un código de verificación en el teclado del teléfono.

Cuando se registra en una cuenta de AWS, se crea una cuenta de usuario raíz de AWS. Este usuario tiene acceso a todos los recursos y los servicios de AWS en la cuenta. Como práctica recomendada de seguridad, asigne acceso administrativo a un usuario y utilice únicamente el usuario raíz para llevar a cabo [tareas que requieren acceso de usuario raíz](#).

AWS le enviará un correo electrónico de confirmación cuando complete el proceso de registro. Se puede ver la actividad de la cuenta y administrarla en cualquier momento entrando en <https://aws.amazon.com/> y seleccionando Mi cuenta.

Proteger el usuario raíz de la cuenta de AWS

1. Inicie sesión en la [Consola de administración de AWS](#) como propietario de la cuenta; para ello, elija Usuario raíz e ingrese el correo electrónico de la cuenta de AWS. En la siguiente página, escriba su contraseña.

Para obtener ayuda para iniciar sesión con el usuario raíz, consulte [Iniciar sesión como usuario raíz](#) en la Guía de inicio de sesión del usuario de AWS.

2. Active la autenticación multifactor (MFA) para el usuario raíz.

Para obtener instrucciones, consulte [Habilitación de un dispositivo MFA virtual para su usuario raíz de la cuenta de AWS \(consola\)](#) en la Guía del usuario de IAM.

Necesito instalar la AWS CLI o un AWS SDK

Para instalar la AWS, siga los pasos que se indican en [Instalación o actualización de la versión más reciente de la AWS](#).

Para instalar un AWS SDK, seleccione la pestaña correspondiente al lenguaje de programación que desea usar en [Herramientas para crear en AWS](#).

Los kits de desarrollo de software (SDK) de AWS están disponibles en muchos lenguajes de programación de uso común. Cada SDK proporciona una API, ejemplos de código y documentación que facilitan a los desarrolladores la creación de aplicaciones en su lenguaje preferido. Los SDK realizan automáticamente tareas muy útiles para usted, como:

- firma criptográfica de las solicitudes de servicio,
- reintento de solicitudes,
- gestión de las respuestas de error.

Obtención de credenciales para conceder acceso programático

Los usuarios necesitan acceso programático si desean interactuar con AWS fuera de la Consola de administración de AWS. La forma de conceder el acceso programático depende del tipo de usuario que acceda a AWS.

Para conceder acceso programático a los usuarios, seleccione una de las siguientes opciones.

¿Qué entidad principal necesita acceso programático?	Para	Mediante
Usuarios de IAM	Limitar la duración de credenciales a largo plazo para firmar las solicitudes programáticas a la AWS CLI, los AWS SDK o las API de AWS.	Siga las instrucciones de la interfaz que desea utilizar: • Para la AWS CLI, consulte Autenticación mediante credenciales de usuario de IAM en la Guía del usuario de la Interfaz de la línea de comandos de AWS.

¿Qué entidad principal necesita acceso programático?	Para	Mediante
		• Para ver los AWS SDK y las herramientas, consulte Autenticar mediante credenciales a largo plazo en la Guía de referencia de AWS SDK y herramientas. • Para las API de AWS, consulte Administración de claves de acceso para usuarios de IAM en la Guía del usuario de IAM.
Roles de IAM	Utilice credenciales temporales para firmar las solicitudes programáticas en la AWS CLI, los AWS SDK o las API de AWS.	Siga las instrucciones de Uso de credenciales temporales con recursos de AWS de la Guía del usuario de IAM.
Usuarios administrados en IAM Identity Center	Utilice credenciales temporales para firmar las solicitudes programáticas en la AWS CLI, los AWS SDK o las API de AWS.	Siga las instrucciones de la interfaz que desea utilizar: • Para la AWS CLI, consulte Configuración de la AWS CLI para usar IAM Identity Center en la Guía del usuario de la Interfaz de la línea de comandos de AWS. • Para los AWS SDK, las herramientas y las API de AWS, consulte Autenticación de IAM Identity Center en la Guía de referencia de las herramientas y los AWS SDK.

Cómo adjuntar permisos de Amazon Bedrock a un usuario o rol

Después de configurar las credenciales para el acceso programático, debe configurar los permisos para que un usuario o rol de IAM pueda acceder a acciones relacionadas con Amazon Bedrock. Para configurar estos permisos, haga lo siguiente:

1. En la página de inicio de la Consola de administración de AWS, seleccione el servicio de IAM o vaya a la consola de IAM en <https://console.aws.amazon.com/iam/>.
2. Seleccione Usuarios o Roles y, a continuación, seleccione su usuario o rol.
3. En la pestaña Permisos, elija Agregar permisos y, a continuación, Agregar políticas administradas por AWS. Elija la política administrada de AWS [AmazonBedrockFullAccess](#).
4. Para permitir que el usuario o el rol se suscriban a los modelos, seleccione Crear política insertada y, a continuación, especifique los siguientes permisos en el editor JSON:

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

Generación de una respuesta para una petición de texto mediante un modelo de Amazon Nova

Una vez que haya cumplido con todos los requisitos previos, puede probar cómo hacer solicitudes de invocación de modelos a modelos de Amazon Nova con una solicitud de [Converse](#).

Para instalar la AWS, siga los pasos que se indican en [Instalación o actualización de la versión más reciente de la AWS](#). Compruebe que ha configurado sus credenciales para usar Boto3 siguiendo los pasos que se indican en [Obtención de credenciales para conceder acceso programático](#).

Para generar una respuesta a una petición de texto en Nova 2 Lite mediante la AWS CLI, ejecute el siguiente comando en un 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"}}'
```


Inferencia básica

La inferencia es el proceso de enviar una solicitud a un modelo de Amazon Nova y recibir una respuesta generada. Los modelos de Amazon Nova admiten la inferencia a través de dos opciones de API:

- API de Converse ([Converse](#), [ConverseStream](#)): proporciona una interfaz coherente en los diferentes modelos, lo que facilita el cambio entre modelos o la creación de aplicaciones que funcionen con varios modelos. Se recomienda para la mayoría de los casos de uso.
- API de Invoke ([InvokeModel](#), [InvokeModelWithResponseStream](#)): las cargas útiles de las solicitudes están estructuradas específicamente para el formato nativo de cada modelo. Ejecuta la inferencia con los parámetros de petición e inferencia proporcionados en el cuerpo de la solicitud.

Ambas API admiten las mismas características básicas, que incluyen lo siguiente:

- Conversaciones de varios turnos
- Entradas multimodales (texto, imágenes, video, audio)
- Uso de herramienta
- Barreras de protección
- Respuestas de transmisión

La estructura de la solicitud es casi idéntica entre las dos API y solo se diferencia en la forma en que se codifican los datos de bytes (documentos, imágenes, video y audio). Para los parámetros de la solicitud de modelos exclusivos de los modelos de Amazon Nova, como `reasoningConfig` y `TopK`, estos se colocan dentro de un objeto `inferenceConfig` adicional dentro de `additionalModelRequestFields`. Estos son parámetros de nivel superior para `InvokeModel` y `InvokeModelWithResponseStream`.

Note

Consulte [Code Samples](#) y [Solución de problemas](#) para obtener una lista de muestras de código con modelos de Nova 2.

Establezca `modelId` en una de las siguientes opciones para utilizar los modelos de Amazon Nova:

Modelo	ID del 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
Nova Multimodal Embeddings	amazon.nova-2-multimodal-embeddings-v1:0

Importante: Configuración del tiempo de espera

Important

Las solicitudes de inferencia de Amazon Nova pueden tardar hasta 60 minutos en completarse. Establezca la configuración del tiempo de espera del cliente en consecuencia: A continuación se muestra un ejemplo de código de Python. Los usuarios pueden consultar la documentación para ver la versión en el idioma del SDK que prefieran en los documentos de la API del SDK.

```
from botocore.config import Config

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

Temas de inferencia básica

En esta sección, se tratan los siguientes temas:

- Uso de la API de Converse: interfaz coherente que ofrece compatibilidad con la mayoría de los modelos de Bedrock

- Uso de la API de Invoke: interfaz exclusiva de los modelos de Nova y no portátil para otros modelos de Bedrock
- Respuestas de transmisión: generación de respuestas en tiempo real
- Uso de incrustaciones de Amazon Nova: capacidades de incrustación de texto
- Inferencia bajo demanda: modelo de inferencia de pago por uso

Uso de la API de Converse

La API de Converse proporciona una interfaz unificada para interactuar con los modelos de Amazon Nova. Resume los detalles específicos del modelo y proporciona una forma coherente de gestionar las conversaciones de varios turnos, las peticiones del sistema y las respuestas de transmisión en todos los modelos de Amazon Nova.

Temas

- [Estructura de la solicitud](#)
- [Uso de peticiones del sistema](#)
- [Parámetros de inferencia](#)
- [Uso del razonamiento](#)

Estructura de la solicitud

- Conversaciones de varios turnos: mantenga el contexto en varios intercambios.
- Peticiones del sistema: son instrucciones del sistema, como personalidades o directrices de respuesta.
- Chat de documentos: interactúe con documentos o colecciones de documentos y consúltelos.
- Visión: procese y analice imágenes y videos.
- Uso de herramientas: permita que los modelos utilicen herramientas y API externas.
- Barreras de protección: aplique filtros de contenido y controles de seguridad.
- Razonamiento: habilite el pensamiento extendido para la resolución de problemas complejos.

Una solicitud básica de la API de Converse incluye el ID del modelo y una lista de mensajes:

```
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 peticiones del sistema

Las peticiones del sistema proporcionan instrucciones y contexto al 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)
```

Parámetros de inferencia

Controle la salida del modelo mediante parámetros de inferencia. A continuación se muestran los parámetros de inferencia disponibles.

- **maxTokens** (entero): número máximo de tokens que se generarán (hasta 65 000). Si no se especifica, el modelo utiliza un valor predeterminado dinámico basado en el contexto de la solicitud.
- **temperatura** (flotante): controla la aleatoriedad (entre 0,0 y 1,0; predeterminado: 0,7). Los valores más bajos hacen que la salida sea más determinista.
- **topP** (flotante): umbral de muestreo del núcleo (entre 0 y 1, predeterminado: 0,9). Los valores más bajos hacen que la salida sea más centrada.
- **stopSequences** (matriz): secuencias de caracteres que detienen la generación cuando se encuentran.

Ejemplo:

```
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 del razonamiento

Nova 2 Lite admite el pensamiento extendido para la resolución de problemas complejos. Habilite el razonamiento con `reasoningConfig`.

De forma predeterminada, el razonamiento está desactivado para optimizar la velocidad y el costo de las consultas sencillas. Cuando necesite ir más allá de estas sencillas tareas, puede habilitar el razonamiento. Nova 2 proporciona un control flexible sobre la profundidad del razonamiento a través de tres niveles de esfuerzo:

Esfuerzo bajo (`maxReasoningEffort: "low"`)

IDEAL PARA: TAREAS CON MAYOR COMPLEJIDAD QUE REQUIEREN UN PENSAMIENTO ESTRUCTURADO. Por ejemplo, puede utilizarlo para hacer sugerencias de revisión y mejora del código en las que el modelo deba tener en cuenta detenidamente la calidad del código existente, llevar a cabo tareas de análisis que requieran tener en cuenta detenidamente varios factores o situaciones de resolución de problemas que se beneficien de un enfoque metódico. El esfuerzo bajo es ideal para tareas complejas en las que el razonamiento básico mejore la precisión sin requerir una planificación profunda de varios pasos.

Esfuerzo medio (`maxReasoningEffort: "medium"`)

IDEAL PARA: TAREAS DE VARIOS PASOS Y FLUJOS DE TRABAJO DE CODIFICACIÓN. Por ejemplo, puede utilizarlo para el desarrollo y la depuración de software cuando el modelo necesite comprender la estructura del código existente antes de implementar los cambios, la generación de código que requiere la coordinación entre varios archivos o componentes, los cálculos de varios pasos con interdependencias o la planificación de tareas con varias restricciones. Un esfuerzo medio es óptimo para flujos de trabajo agénticos que coordinan varias herramientas y requieren que el modelo mantenga el contexto en varias operaciones secuenciales.

Esfuerzo alto (`maxReasoningEffort: "high"`)

IDEAL PARA: RAZONAMIENTO STEM Y RESOLUCIÓN AVANZADA DE PROBLEMAS. Por ejemplo, puede utilizarlo para pruebas y problemas matemáticos avanzados que requieran una verificación minuciosa, tareas de análisis e investigación que requieran una investigación

exhaustiva, diseños de sistemas complejos con consideraciones arquitectónicas en varias dimensiones o casos críticos de toma de decisiones con implicaciones significativas. Un esfuerzo alto proporciona la máxima precisión para tareas que requieran un razonamiento sofisticado, una evaluación cuidadosa de las alternativas y una validación exhaustiva de las conclusiones.

En los siguientes ejemplos, se muestran los diferentes niveles de esfuerzo de razonamiento:

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"
        }
    }
)
```

Parámetros de razonamiento:

A continuación se muestran los parámetros de razonamiento:

- `type`: `enabled` o `disabled` (predeterminado: `disabled`)
- `maxReasoningEffort`: `low`, `medium`, o `high`. Es obligatorio cuando el razonamiento está habilitado.

Note

Temperatura, TopP y TopK no se pueden usar con `maxReasoningEffort` establecido en `high`. Producirá un error.

La respuesta incluye contenido de razonamiento:

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

Note

Con Amazon Nova 2, el contenido de razonamiento se muestra como `[REDACTED]`. Se le continuará cobrando por los tokens de razonamiento, ya que contribuyen a mejorar la calidad de la salida. Ahora incluimos este campo en la estructura de la respuesta para preservar la opción de exponer el contenido del razonamiento en el futuro. Estamos trabajando activamente con los clientes para determinar el mejor enfoque para dar a conocer el proceso de razonamiento del modelo.

Uso de la API de Invoke

La API de Invoke proporciona acceso directo a los modelos de Amazon Nova con más capacidad para controlar el formato de solicitud y respuesta. A diferencia de la API de Converse, que resume los detalles específicos del modelo, la API de Invoke le permite trabajar directamente con las estructuras de solicitud y respuesta nativas del modelo.

Note

La API de Invoke admite las mismas características que la API de Converse, excepto la modalidad de entrada de documentos, que es específica de la API de Converse.

Estructura de la solicitud

Una solicitud de la API de Invoke requiere el ID del modelo y el cuerpo de la solicitud en formato 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"])
```

Parámetros de solicitud

La API de Invoke admite los siguientes parámetros claves:

- **messages**: matriz de mensajes de conversación con rol y contenido
- **system**: petición del sistema opcional para el contexto y las instrucciones
- **inferenceConfig**: parámetros que controlan la salida del modelo (temperatura, maxTokens, topP, topK, stopSequences, reasoningConfig)
- **toolConfig**: especificaciones y elección de la herramienta para la llamada a funciones

Respuestas de transmisión

La transmisión permite recibir las respuestas del modelo de forma incremental a medida que se generan, lo que proporciona una experiencia del usuario más interactiva. Tanto la API de Converse como la API de Invoke admiten la transmisión.

Transmisión con ConverseStream

Utilice `ConverseStream` para recibir respuestas como una secuencia 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)
```

Transmisión con InvokeModelWithResponseStream

Utilice `InvokeModelWithResponseStream` para transmitir con la API de 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 eventos de transmisión

Las respuestas de transmisión incluyen varios tipos de eventos:

- `messageStart`: indica el inicio de un mensaje.

- `contentBlockStart`: indica el inicio de un bloque de contenido.
- `contentBlockDelta`: contiene texto o datos incrementales.
- `contentBlockStop`: indica el final de un bloque de contenido.
- `messageStop`: indica el final del mensaje con el motivo de la detención.
- `metadata`: contiene información de uso (recuentos de tokens).

Uso de incrustaciones de Amazon Nova

Amazon Nova Multimodal Embeddings es un modelo de incrustaciones multimodales para aplicaciones búsqueda semántica y RAG agéntica. Admite texto, documentos, imágenes, video y audio en un único modelo, lo que permite la recuperación intermodal. Nova Multimodal Embeddings asigna cada uno de estos tipos de contenido a un espacio semántico unificado, lo que le permite llevar a cabo operaciones vectoriales unimodales, intermodales y multimodales.

Cuando un contenido pasa por las incrustaciones de Nova, el modelo convierte ese contenido en un formato numérico universal, denominado vector. Un vector es un conjunto de valores numéricos que se pueden utilizar para diversas funcionalidades de búsqueda. Al contenido similar se le asigna un vector más cercano que al contenido menos similar.

Aplicaciones:

- Recuperación y recomendación de contenido semántico: genere incrustaciones para su contenido y utilícelas para buscar elementos similares u ofrecer recomendaciones personalizadas.
- Búsqueda multimodal: combine incrustaciones de diferentes tipos de contenido para facilitar capacidades de búsqueda intermodal.
- RAG: genere incrustaciones a partir de contenido multimodal, como documentos con texto e imágenes intercalados, para potenciar el flujo de trabajo de recuperación de las aplicaciones GenAI.

Características principales de

Estas características clave distinguen a Nova Embeddings:

- Soporte de texto, imagen, imagen de documento, video y audio en un espacio semántico unificado. La longitud máxima del contexto es de 8000 tokens o 30 segundos de video y 30 segundos de audio.

- API sincrónicas y asincrónicas: la API admite el uso sincrónico y asincrónico.
- Segmentación de archivos grandes: la API asincrónica facilita el trabajo con entradas de gran tamaño al proporcionar una segmentación creada por la API para texto, video y audio largos, controlada mediante parámetros que define el usuario. El modelo generará una incrustación única para cada segmento.
- Video con audio: procese video y audio de forma simultánea. Especifique si desea una sola incrustación que represente ambas modalidades o dos incrustaciones independientes.
- Propósito de la incrustación: optimice sus incrustaciones en función de la aplicación descendiente prevista (recuperación, RAG, búsqueda, clasificación, agrupación en clústeres).
- Tamaños: 4 tamaños para compensar la precisión de incrustación y el costo de almacenamiento vectorial: 3072, 1024, 384 y 256.
- Métodos de entrada: para transmitir contenido a fin de incrustarlo, especifique un URI de S3 o en línea como codificación base64.

Generación de incrustaciones

Complete lo siguiente para generar incrustaciones.

Incrustación sincrónica 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))

```

prueba:

```

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))

```

Incrustación asíncrona para video:

```

import boto3

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

```

```

)

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

```

pruebe:

```

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'))

```

Inferencia en lotes

Con la inferencia en lotes, puede enviar varias solicitudes y generar respuestas de forma asíncrona. La inferencia en lotes le permite procesar varias solicitudes de manera eficiente al enviar una sola solicitud y generar respuestas en un bucket de Amazon S3.

- Una vez definidas las entradas del modelo en los archivos que cree, los archivos se cargan a un bucket de S3.
- A continuación, envía una solicitud de inferencia por lotes y especifica el bucket de S3.
- Una vez finalizado el trabajo, podrá recuperar los archivos de salida de S3.
- Puede utilizar la inferencia por lotes para mejorar el rendimiento de la inferencia de modelos en conjuntos de datos de gran tamaño.

Formateo y carga de los datos de la inferencia por lotes

Debe añadir los datos de inferencia en lotes a la ubicación de S3 que elija o especifique al enviar un trabajo de invocación de modelos. La ubicación de S3 debe contener los siguientes elementos:

Al menos un archivo JSONL que defina las entradas del modelo. Un JSONL contiene filas de objetos JSON. El archivo JSONL debe terminar con la extensión .jsonl y tener el siguiente 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 entradas de archivos admitidos

- Formatos de imagen: PNG, JPEG, WEBP, GIF
- Formatos de audio: MP3, WAV, OGG
- Formatos de video: MP4, MOV, MKV, WEBM, FLV, MPEG, MPG, WMV, 3GP

Inferencia bajo demanda

La inferencia bajo demanda proporciona acceso sin servidor a los modelos de Amazon Nova sin necesidad de capacidad aprovisionada. Este modo escala automáticamente para gestionar la carga de trabajo y los cargos en función del uso.

Ventajas

La inferencia bajo demanda ofrece varias ventajas:

- Sin planificación de la capacidad: escala automáticamente para satisfacer la demanda.
- Pago por uso: solo pagará por los tokens procesados.
- Disponibilidad instantánea: no se requiere tiempo de aprovisionamiento ni calentamiento.
- Rentable: ideal para cargas de trabajo variables o impredecibles.

Uso de la inferencia bajo demanda

La inferencia bajo demanda es el modo predeterminado de los modelos de Amazon Nova. Solo tiene que especificar el ID del modelo al hacer llamadas a la 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)
```

Precios

La inferencia bajo demanda se factura en función del número de tokens de entrada y salida procesados. Para obtener los detalles sobre los precios, consulte [Precios de Amazon Bedrock](#).

Cuotas y límites

La inferencia bajo demanda tiene cuotas predeterminadas que varían según el modelo y la región. Para solicitar un aumento de la cuota, use la [consola de Service Quotas](#).

Uso de las capacidades de Amazon Nova 2

En esta guía, se proporcionan fórmulas basadas en tareas y ejemplos prácticos que le permitirán integrar las capacidades de Nova en sus aplicaciones de forma rápida y eficaz. Está diseñada para desarrolladores e ingenieros que desean:

- Integrar modelos Nova en sus aplicaciones a través de la API
- Comprender los requisitos de preprocesamiento y las estrategias de optimización
- Implementar flujos de trabajo de comprensión multimodales

Cada sección proporciona:

- Información técnica clave sobre los formatos compatibles, los límites de tamaño y la estimación de los tokens
- Ejemplos de código que muestran cómo utilizar la API con la carga directa y con Amazon S3
- Casos de uso que muestran aplicaciones prácticas
- Limitaciones que debe tener en cuenta al diseñar la aplicación

Requisitos previos

Antes de comenzar, asegúrese de que dispone de lo siguiente:

- Una Cuenta de AWS con acceso a Amazon Bedrock
- Permisos de IAM adecuados para invocar modelos de Bedrock
- AWS SDK instalado (ejemplos de Boto3 para Python)
- Familiaridad básica con servicios de AWS, como Amazon S3 (para la gestión de archivos de gran tamaño)

Capacidades de razonamiento

Amazon Nova 2 Lite admite el pensamiento extendido, que está desactivado de forma predeterminada. Al habilitarlo, el modelo genera tokens de razonamiento interno que mejoran la calidad de la respuesta. En Amazon Nova 2 Lite, el contenido de razonamiento aparece redactado en la salida y se muestra como [REDACTED], aunque se le continuará cobrando por estos tokens.

El campo de razonamiento se incluye en la estructura de la respuesta para preservar la opción de exponer este contenido en futuras versiones. Para obtener más información sobre el pensamiento extendido, consulte [the section called “Pensamiento extendido”](#) y [the section called “Biblioteca de códigos”](#).

Comprensión multimodal

Amazon Nova 2 Lite puede comprender varias modalidades de entrada. Este modelo está equipado con capacidades de visión que le permiten comprender y analizar imágenes, documentos, videos y voz para inferir y responder preguntas en función del contenido proporcionado.

En esta sección, se describen las directrices para trabajar con imágenes, documentos y videos en Amazon Nova, lo que incluye las estrategias de preprocesamiento empleadas, los ejemplos de código y las limitaciones relevantes que se deben tener en cuenta.

Tipo de contenido compatible por modalidad

A continuación, se detallan los formatos de archivo compatibles con cada tipo de archivo multimedia y el método de entrada aceptado.

Tipo de archivo multimedia	Formatos de archivo compatibles	Método de entrada	Límites de tamaño	Número de objetos
Image	PNG, JPEG, GIF, WebP	Incrustación de datos en la solicitud	25 MB	5
	Nota: Si utiliza un archivo WebP o GIF animado, solo se utilizará el primer fotograma.	Si usa la API de Converse, codifique los datos como bytes. Si usa la API de Invoke, codifique los datos como una cadena Base64.		
		URI de Amazon S3	2 GB en total	1 000

Tipo de archivo multimedia	Formatos de archivo compatibles	Método de entrada	Límites de tamaño	Número de objetos
Video	MP4, MOV, MKV, WebM, FLV, MPEG, MPG, WMV, 3GP	Incrustación de datos en la solicitud Si usa la API de Converse, codifique los datos como bytes. Si usa la API de Invoke, codifique los datos como una cadena Base64.	25 MB	1
		URI de Amazon S3	1 GB	1

Temas

- [Comprensión de imágenes](#)
- [Comprensión de videos](#)
- [Comprensión de documentos](#)

Comprensión de imágenes

La comprensión de imágenes se refiere a la capacidad de Amazon Nova para procesar una imagen y llevar a cabo diversas tareas de visión artificial, tales como:

- Detección de objetos
- Respuesta a preguntas sobre imágenes mediante la respuesta a preguntas visuales (VQA)
- Clasificación y resumen de imágenes
- Detección de cuadro delimitadores
- Reconocimiento óptico de caracteres (OCR)
- Recuento de objetos

Las imágenes se pueden incluir como petición que se pasa a la API como matrices de bytes o mediante el URI de S3.

Información técnica clave

A continuación se muestra información técnica clave que se debe tener en cuenta al trabajar con esta capacidad.

Cambio de tamaño y reescalado de imágenes

Amazon Nova cambia automáticamente el tamaño de las imágenes para optimizar la calidad y el rendimiento:

- Determina la relación de aspecto más cercana (por ejemplo, 1:1, 1:2, 2:3, etc.).
- Cambia la escala para que un lado sea ≥ 896 px o coincida con el lado más corto de la imagen original, el que sea más grande.
- Mantiene la relación de aspecto.
- Admite una resolución de hasta 8000×8000 px.

Coordenadas del cuadro delimitador:

- Es útil para tareas como la identificación de elementos en capturas de pantalla o la localización de imágenes.
- Se puede cambiar la escala de las coordenadas para que coincidan con las dimensiones originales de la imagen durante el posprocesamiento.
- Devuelve los cuadros delimitadores en una escala de $[0, 1000]$.

Estimación por token de imagen

Amazon Nova convierte cada imagen en tokens para su procesamiento. El número de tokens depende de la resolución y la relación de aspecto de la imagen.

A continuación se muestran ejemplos de recuentos aproximados de token en función de la resolución de la imagen:

Resolución de la imagen	Tokens estimados
900 x 450	515

Resolución de la imagen	Tokens estimados
900 x 900	~1035
1400 x 900	~1600
1800 x 900	~2060
1300 x 1300	~2155

Ejemplos de comprensión de imágenes

Para ver un ejemplo de cómo incrustar datos de imagen directamente en la solicitud, consulte el ejemplo de entrada multimodal mediante un activo integrado: API de Converse (sin transmisión) en [Biblioteca de códigos](#).

Para cargar archivos de imagen de gran tamaño o varios archivos de imagen, en los que la carga útil total sea superior a 25 MB, utilice Amazon S3. Para ver un ejemplo completo de cómo utilizar las referencias de URI de Amazon S3 para la entrada de imágenes, consulte el ejemplo de entrada multimodal con URI de S3: API de Converse (sin transmisión) en [Biblioteca de códigos](#).

Note

Cuando utilice S3, asegúrese de que el servicio de Amazon Bedrock tenga permiso para acceder al bucket y al objeto.

Limitaciones clave

En la siguiente lista, se describen las limitaciones actuales de los modelos de comprensión de imágenes:

- **Comprensión de imágenes multilingües:** los modelos tienen una comprensión limitada de las imágenes y los fotogramas de video multilingües y pueden tener dificultades o alucinar en tareas sencillas.
- **Identificación de personas:** los modelos de Amazon Nova 2 no admiten la capacidad de identificar o nombrar a personas en imágenes, documentos o videos.

- **Razonamiento espacial:** los modelos de Amazon Nova 2 tienen capacidades de razonamiento espacial limitadas. Es posible que tengan dificultades con las tareas que requieren una localización precisa o un análisis de disposición.
- **Texto pequeño en imágenes y videos:** si el texto de la imagen o el video es demasiado pequeño, considere la posibilidad de recortar la imagen hasta la sección pertinente y conservar el contexto necesario para aumentar el tamaño relativo del texto en la imagen.

Comprensión de videos

La comprensión de video se refiere a la capacidad de Amazon Nova para procesar entradas de video y llevar a cabo diversas tareas de comprensión de video, tales como:

- Análisis de fotogramas clave y resumen del contenido de videos
- Respuesta a preguntas sobre segmentos de video (respuesta a preguntas de videos o control de calidad de videos)
- Detección y seguimiento de objetos a través de fotogramas
- Identificación de acciones, escenas y eventos
- Segmentación temporal para localizar momentos específicos
- Generación de subtítulos descriptivos o resúmenes de secuencias de video

Información técnica clave

A continuación se muestra información técnica clave que se debe tener en cuenta al trabajar con esta capacidad.

Información sobre el tamaño del video

Las capacidades de comprensión de videos de Amazon Nova admiten múltiples relaciones de aspecto. Todos los videos se redimensionan con distorsión (hacia arriba o hacia abajo, según la relación de aspecto original) hasta alcanzar dimensiones cuadradas de 672 x 672 antes de su entrada en el modelo.

El modelo utiliza una estrategia de muestreo dinámico en función de la duración del video. Para videos de 16 minutos o menos, Amazon Nova 2 Lite muestreará 1 fotograma por segundo (FPS). Para los videos de más de 16 minutos, la frecuencia de muestreo disminuye para mantener un muestreo constante de 960 fotogramas, con una variación de la frecuencia de muestreo de

fotogramas en consecuencia. Este enfoque está diseñado para proporcionar una comprensión más precisa del video a nivel de escena en los videos más cortos en comparación con los de mayor duración.

Le recomendamos que mantenga la duración del video en menos de 1 hora en cámara lenta y en menos de 16 minutos para cualquier contenido con mayor movimiento.

No debería haber ninguna diferencia al analizar una versión 4K de un video y una versión Full HD. Del mismo modo, dado que la frecuencia de muestreo es de 1 FPS, un video de 60 FPS debería funcionar tan bien como un video de 30 FPS. Utilizar una resolución y un FPS superiores a los necesarios no es beneficioso debido al límite de 1 GB en el tamaño del video. Al hacerlo, se limitará la duración del video que se ajusta a ese límite de tamaño, por lo que es posible que desee preprocesar videos de 1 GB.

Tokens de video

La duración del video es el factor principal que afecta al número de tokens generados. Para calcular el costo aproximado, multiplique el número estimado de tokens de video por el precio por token del modelo específico que utilice.

En la siguiente tabla, se proporcionan algunas aproximaciones del muestreo de fotogramas y el uso de tokens según la duración del video para Amazon Nova 2 Lite:

Duración del video	Fotogramas para muestrear	FPS de la velocidad de muestreo	Tokens aproximados
10 segundos	10	1	2880
30 segundos	30	1	8640
16 minutos	960	1	276 480
20 minutos	1200	1	345 600
30 minutos	1800	1	518 400
45 minutos	2700	1	777 600

Ejemplos de comprensión de videos

Para ver un ejemplo de cómo incrustar datos de video directamente en la solicitud, consulte el ejemplo de entrada multimodal mediante un activo integrado: API de Converse (sin transmisión) en [Biblioteca de códigos](#).

Para obtener un ejemplo de cómo utilizar las referencias de URI de S3 en una entrada de video, consulte el ejemplo de entrada multimodal con URI de S3: API de Converse (sin transmisión) en [Biblioteca de códigos](#).

Limitaciones clave

A continuación se muestran las principales limitaciones del modelo, en las que es posible que no se garanticen su precisión y rendimiento.

- Sin soporte de audio: actualmente, los modelos de Amazon Nova están entrenados para procesar y comprender el contenido de video solo en función de los fotogramas visuales. Las pistas de audio de los videos no se procesan ni analizan.
- Comprensión de imágenes multilingües: los modelos de Amazon Nova tienen una comprensión limitada de imágenes y fotogramas de video multilingües. Podrían tener dificultades o alucinar en tareas sencillas.
- Identificación de personas: los modelos de Amazon Nova no admiten la capacidad de identificar o nombrar a personas en imágenes, documentos o videos. Los modelos no proporcionarán nombres ni identidades de personas en el contenido visual.
- Texto pequeño en videos: si el texto de la imagen o el video es demasiado pequeño, considere la posibilidad de aumentar el tamaño relativo del texto en el video.
- Razonamiento espacial: los modelos de Amazon Nova 2 tienen capacidades de razonamiento espacial limitadas. Es posible que tengan dificultades con las tareas que requieren una comprensión precisa de las posiciones, las distancias o las relaciones espaciales de los objetos en los videos.
- Contenido inapropiado: los modelos de Amazon Nova no procesarán imágenes inapropiadas o explícitas que infrinjan la Política de uso aceptable.
- Aplicaciones en la atención de salud: debido a la naturaleza sensible de estos elementos, aunque los modelos de Amazon Nova pueden ofrecer análisis generales de algunas imágenes o videos relacionados con la atención sanitaria, no recomendamos su uso para interpretar imágenes médicas sensibles, como imágenes de diagnóstico complejas. La respuesta de los modelos de Amazon Nova nunca debe considerarse un sustituto del asesoramiento médico profesional.

Comprensión de documentos

La capacidad de comprensión de documentos de Amazon Nova le permite incluir documentos completos (PDF, archivos de Word, hojas de cálculo, etc.) como parte de la petición. Esto permite al modelo analizar, resumir, extraer información o responder a preguntas sobre el contenido del documento.

Amazon Nova 2 Lite puede interpretar tanto el texto como los elementos visuales (como gráficos o tablas) de estos documentos. Esto permite casos de uso como contestar preguntas, resumir y analizar informes largos o documentos escaneados.

Las características de compresión de documentos clave incluyen una cantidad de contexto muy grande (1 millón de tokens) para documentos largos y la capacidad de gestionar varios documentos en una sola consulta.

Modalidades y formatos de documentos admitidos

Amazon Nova distingue entre dos tipos de entradas de documentos:

- Documentos basados en texto, como los archivos TXT, CSV, Markdown, HTML o DOC, que se procesan principalmente por su contenido textual. Amazon Nova comprende y extrae información del texto de estos documentos.
- Documentos basados en contenido multimedia, como archivos PDF o DOCX, que pueden contener diseños, imágenes, gráficos o contenido gráfico incrustado complejos. Para los documentos basados en contenido multimedia, Amazon Nova emplea un análisis basado en la visión para interpretar el contenido visual, como gráficos, tablas, diagramas o capturas de pantalla, junto con el texto del documento.

Los formatos de archivo admitidos incluyen tipos de documentos comunes, como:

- Archivos de texto sin formato y de texto estructurado: CSV, TXT
- Hojas de cálculo: XLS, XLSX, HTML, Markdown
- Formatos de imagen estándar (para imágenes dentro de documentos): PNG, JPG, GIF, WebP
- Formatos de documento: DOC, DOCX, PDF
- No se admiten los archivos PDF que contienen codificaciones de imagen, como CMYK o SVG.

Límites de tamaño de los documentos y directrices de uso

Restricción	Límite
Número máximo de documentos	Hasta 5 documentos por solicitud (se aplica tanto a la carga directa como a Amazon S3)
Tamaño del documento basado en texto	Cada documento de texto debe tener un tamaño de 4,5 MB o menos
Tamaño del documento basado en contenido multimedia	En el caso de los archivos PDF y DOCX, no existe un límite de tamaño de archivo individual. Al utilizar la carga directa, el tamaño combinado de todos los documentos multimedia debe ser igual o inferior a 25 MB. Al utilizar Amazon S3, el tamaño combinado de todos los documentos multimedia debe ser igual o inferior a 2 GB.
Contenido en PDF no compatible	No se admiten archivos PDF que contengan perfiles de color CMYK o imágenes SVG.

Precios

Amazon Nova utiliza precios basados en tokens: pagará por los tokens de entrada (todo lo que envía, incluidos los documentos adjuntos) y de salida (la respuesta del modelo).

Estimación de tokens para archivos PDF: a modo de planificación, supongamos que una página PDF estándar de 8,5 x 11 pulgadas equivale a 2560 tokens de entrada (esta estimación abarca tanto el texto como los elementos visuales de una página normal).

Ejemplo: uso de la comprensión de documentos de Nova a través de la API y S3

Para ver un ejemplo de cómo usarlo a través de una API, consulte el ejemplo de entrada multimodal con un activo integrado: API de Converse (sin transmisión) en [Biblioteca de códigos](#).

Para ver un ejemplo de cómo usarla a través de S3, consulte el ejemplo de entrada multimodal con URI de S3: API de Converse (sin transmisión) en [Biblioteca de códigos](#).

Voz a voz (Amazon Nova 2 Sonic)

Amazon Nova 2 Sonic permite la IA conversacional en tiempo real con entrada y salida de voz. En la siguiente sección, se describen las capacidades avanzadas para crear asistentes de voz interactivos, automatización del servicio de atención al cliente y aplicaciones conversacionales.

Características principales de

Amazon Nova 2 Sonic ofrece las siguientes capacidades:

- Comprensión de transmisión de voz de última generación con API de transmisión bidireccional que permite conversaciones en tiempo real y de baja latencia en varios turnos.
- Soporte multilingüe con detección y cambio automáticos de idioma. Se ofrecen voces expresivas, tanto masculinas como femeninas, en los siguientes idiomas:
 - Inglés (EE. UU., Reino Unido, India, Australia)
 - Francés
 - Italiano
 - Alemán
 - Español
 - Portugués
 - Hindi
- Voces políglotas que pueden hablar cualquiera de los idiomas admitidos para ofrecer una experiencia de usuario uniforme incluso cuando el usuario cambia de idioma en la misma sesión.
- Claridad frente al ruido de fondo para situaciones de implementación reales.
- Claridad con diferentes acentos para los idiomas admitidos.
- Experiencias de IA conversacional naturales y similares a las humanas con una riqueza contextual en todos los idiomas admitidos.
- Respuesta de voz adaptativa que ajusta de forma dinámica la entrega en función de la prosodia de la voz de entrada.
- Sistema inteligente de turnos que detecta cuándo los usuarios terminan de hablar y cuándo debe responder el asistente, lo que crea un ritmo de diálogo natural.
- Manejo elegante de las interrupciones de los usuarios sin perder el contexto conversacional.

- Fundamentación del conocimiento con datos empresariales mediante generación aumentada por recuperación (RAG).
- Compatibilidad con llamadas a funciones y flujo de trabajo de agentes para crear aplicaciones de IA complejas.
- Gestión asíncrona de las herramientas que ejecuta las llamadas a las herramientas mientras mantiene el flujo de la conversación, lo que permite al asistente continuar hablando mientras las herramientas procesan en segundo plano.
- Admite entradas multimodales para entradas de audio y texto dentro de la misma conversación, lo que permite patrones de interacción flexibles.
- Límite de conexión de 8 minutos, con un patrón de renovación de la conexión y continuación de la sesión disponible en muestras de código.

Introducción al formato de voz a voz

En las siguientes secciones, se proporciona un ejemplo y una explicación paso a paso de cómo implementar una aplicación sencilla de transmisión de audio en tiempo real con Amazon Nova 2 Sonic. Esta versión simplificada muestra la funcionalidad básica necesaria para crear una conversación de audio con el modelo de Amazon Nova 2 Sonic.

Puede acceder al siguiente ejemplo en nuestro [repositorio de GitHub de muestras de Amazon Nova](#).

Hay un límite de conexión de 8 minutos, con un patrón de renovación de la conexión y continuación de la conversación disponible en [GitHub](#).

Establecimiento de las importaciones y la configuración

En esta sección, se importan las bibliotecas necesarias y se establecen los parámetros de configuración de audio:

- `asyncio`: para la programación asíncrona.
- `base64`: para la codificación y decodificación de datos de audio.
- `pyaudio`: para la captura y reproducción de audio.
- Componentes del SDK de Amazon Bedrock para la transmisión
- Las constantes de audio definen el formato de captura de audio (frecuencia de muestreo 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

```

Definición de la clase **SimpleNovaSonic**

La clase `SimpleNovaSonic` es la clase principal que gestiona la interacción de Amazon Nova Sonic:

- `model_id`: el ID de modelo de Amazon Nova Sonic (`amazon.nova-2-sonic-v1:0`)
- `region`: región de AWS, el valor predeterminado es `us-east-1`.
- ID únicos para el seguimiento de las peticiones y del contenido
- Una cola asíncrona para la reproducción de audio

```

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

```

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

Inicialización del cliente

Este método configura el cliente de Amazon Bedrock con lo siguiente:

- El punto de conexión adecuado para la región especificada.
- Información de autenticación mediante variables de entorno para las credenciales de AWS.
- El esquema de autenticación SigV4 para las llamadas a la API de 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)
```

Gestión de eventos

Este método auxiliar envía los eventos JSON a la transmisión bidireccional, que se utiliza para todas las comunicaciones con el 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)
```


Inicio de sesión

Este método inicia la sesión y configura los eventos restantes para iniciar la transmisión de audio. Estos eventos deben enviarse en el mismo orden.

```
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())

```

Gestión de la entrada de audio

Estos métodos gestionan el ciclo de vida de la entrada de audio:

- `start_audio_input`: configura e inicia el flujo de entrada de audio.
- `send_audio_chunk`: codifica y envía fragmentos de audio al modelo.
- `end_audio_input`: cierra correctamente el flujo de entrada de audio.

```

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

```

```

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

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

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

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

```

```

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

```

Finalización de la sesión

Este método cierra correctamente la sesión mediante lo siguiente:

- envío de un evento `promptEnd`,
- envío de un evento `sessionEnd`,
- cierre del flujo 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()

```

Tratamiento de respuestas

Este método procesa continuamente las respuestas del modelo y hace lo siguiente:

- Espera la salida del flujo.
- Analiza la respuesta JSON.
- Gestiona la salida de texto imprimiéndola en la consola con reconocimiento de voz y transcripción automáticos.
- Gestiona la salida de audio decodificándola y poniéndola en cola para su reproducción.

```
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}")

```

Reproducción de audio

Este método realizará las siguientes tareas:

- Inicializa un flujo de entrada PyAudio.
- Recupera continuamente los datos de audio de la cola.
- Reproduce el audio a través de los parlantes.
- Limpia adecuadamente los recursos al 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
    )

```

pruebe:

```

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()
```

Captura de audio

Este método realizará las siguientes tareas:

- Inicializa un flujo de salida PyAudio.
- Inicia la sesión de entrada de audio.
- Captura fragmentos de audio del micrófono de forma continua.
- Envía cada fragmento al modelo Amazon Nova Sonic.
- Limpia adecuadamente los recursos al 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()
```

pruebe:

```
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()
```

Ejecución de la función principal

La función principal orquesta todo el proceso con las siguientes acciones:

- Crea un cliente de Amazon Nova 2 Sonic.
- Inicia la sesión.
- Crea tareas concurrentes para la reproducción y captura de audio.
- Espera a que el usuario presione **Enter** para detenerse.
- Finaliza correctamente la sesión y limpia las tareas.

```
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())
```

Ejemplos de código

Estos ejemplos de código le permiten comenzar a usar Amazon Nova 2 Sonic rápidamente. Puede acceder a la lista completa de ejemplos en la página de [muestras de GitHub de Amazon Nova Sonic](#).

Ejemplos sobre cómo comenzar

Para obtener ejemplos sencillos diseñados a fin de comenzar a utilizar Amazon Nova 2 Sonic, consulte las siguientes implementaciones:

- [Implementación básica de Amazon Nova 2 Sonic \(Python\)](#): una implementación básica que muestra cómo se estructuran los eventos en la API de transmisión bidireccional. Esta versión no admite la funcionalidad de interrupción (interrumpir al asistente mientras habla) y no implementa una verdadera comunicación bidireccional.

- [Implementación completa de Amazon Nova 2 Sonic \(Python\)](#): es la implementación con todas las características, comunicación bidireccional real y soporte de interrupciones. Esto permite conversaciones más naturales en las que los usuarios pueden interrumpir al asistente mientras habla, de forma similar a las conversaciones humanas.
- [Amazon Nova 2 Sonic con uso de herramientas \(Python\)](#): una implementación avanzada que amplía las capacidades de comunicación bidireccional con ejemplos de uso de herramientas. Esta versión muestra cómo Amazon Nova 2 Sonic puede interactuar con herramientas y API externas para ofrecer una funcionalidad mejorada.
- [Nova Sonic con texto y entrada mixta \(Python\)](#): ejemplo de implementación para mostrar cómo Amazon Nova 2 Sonic puede tener texto como entrada.
- [Implementación de Java WebSocket \(Java\)](#): en este ejemplo, se implementa una aplicación de transmisión de audio bidireccional basada en WebSocket que se integra con el modelo de Amazon Nova 2 Sonic para mantener conversaciones de voz a voz en tiempo real mediante Java.
- [Implementación de NodeJS WebSocket \(NodeJS\)](#): en este ejemplo, se implementa una aplicación de transmisión de audio bidireccional basada en WebSocket que se integra con el modelo de Amazon Nova 2 Sonic para mantener conversaciones de voz a voz en tiempo real mediante NodeJS.
- [Implementación de NodeJS WebSocket \(C#\)](#): en este ejemplo, se implementa una aplicación de transmisión de audio bidireccional basada en WebSocket que se integra con el modelo de Amazon Nova 2 Sonic para mantener conversaciones de voz a voz en tiempo real mediante .NET.

Casos de uso avanzados

Para ver ejemplos avanzados que muestran casos de uso más complejos, consulte las siguientes implementaciones:

- [Implementación de la base de conocimiento de Amazon Bedrock \(NodeJS\)](#): en este ejemplo, se muestra cómo crear una aplicación conversacional inteligente mediante la integración de Amazon Nova 2 Sonic con la base de conocimiento de Amazon Bedrock mediante NodeJS.
- [Administración del historial de chat \(Python\)](#): en este ejemplo, se incluye un sistema de registro del historial de chat que captura y conserva todas las interacciones entre el usuario y Amazon Nova 2 Sonic mediante Python.
- [Cancelación de reservas de hotel \(NodeJS\)](#): en este ejemplo, se muestra un caso de uso de servicio al cliente para Amazon Nova 2 Sonic, en el que se implementa un sistema de cancelación de reservas de hotel mediante NodeJS.

- [Integración de la base de conocimiento de LangChain \(Python\)](#): en esta implementación, se muestra cómo integrar las capacidades de voz a voz de Amazon Nova 2 Sonic con una base de conocimiento basada en LangChain para mejorar las experiencias de conversación mediante Python.
- [Reanudación de conversaciones \(NodeJS\)](#): en este ejemplo, se muestra cómo implementar las capacidades de reanudación de conversaciones con Amazon Nova 2 Sonic. En el contexto de una cancelación de reserva de hotel, la aplicación muestra cómo mantener el estado de la conversación en todas las sesiones, lo que permite a los usuarios continuar sin problemas las interacciones que se habían interrumpido previamente mediante NodeJS.
- [Nova 2 Sonic habla primero \(NodeJS\)](#): en este ejemplo, se muestra cómo Amazon Nova 2 Sonic puede iniciar conversaciones de forma proactiva.
- [Continuación de sesiones \(Python\)](#): en este ejemplo, se muestra cómo habilitar una duración de conversación ilimitada con Amazon Nova 2 Sonic mediante la implementación de transiciones de sesión fluidas. La aplicación crea y cambia automáticamente a nuevas sesiones en segundo plano, lo que permite que las conversaciones continúen indefinidamente sin interrupciones ni pérdida de contexto.

Taller práctico

También hay disponible un taller práctico que le guiará por la creación de una aplicación de chat de voz mediante Amazon Nova 2 Sonic con una interfaz de transmisión bidireccional. Puede [acceder al taller](#) y encontrar los [ejemplos de código completos](#).

Peticiones de conversación de voz

Nova 2 presenta Peticiones de voz, una capacidad de peticiones especializada diseñada para controlar el formato de transcripción específico de la voz en hindi. Las peticiones de voz funcionan junto con las del sistema, pero tienen un propósito distinto:

- Petición del sistema: controla el comportamiento, la personalidad y el estilo de respuesta del asistente.
- Petición de voz: controla el formato de transcripción para cambios de código en hindi (alfabetos latino, devanagari o mixto).

Directrices importantes

Las peticiones de voz están preconfiguradas y deben usarse exactamente como se documenta. Están diseñadas para satisfacer necesidades específicas de formato de transcripción y no deben modificarse ni personalizarse, ya que los cambios pueden provocar un comportamiento inesperado.

Cuándo se deben usar las peticiones de voz:

- Necesita controlar la salida del script para cambios de código en hindi (latino, devanagari o mixto).

Cuándo NO se deben usar las peticiones de voz:

- Para obtener instrucciones generales o el comportamiento del asistente (utilice las peticiones del sistema como alternativa).
- Si no trabaja con el formato de transcripción de hindi.
- Si la necesidad de formato específica no se aplica a su caso de uso.

Práctica recomendada: incluya una petición de voz solo si necesita específicamente el formato de transcripción de hindi. Todas las demás instrucciones (como las preferencias de idioma, el estilo de respuesta, los detalles y el razonamiento) deberían ir en la petición del sistema.

Importante: Las peticiones de voz deben enviarse al modelo después de la petición del sistema.

Petición del sistema de línea de base recomendada 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.

Configuración de peticiones de voz

Cambio de código

Nota: Esta característica solo se aplica actualmente al idioma hindi.

Elija una de las siguientes peticiones en función del alfabeto de salida que desee:

Para la salida en alfabeto latino (hindi romanizado):

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

Para la salida en alfabeto devanagari:

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

Para la salida en alfabeto mixto (cambio 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.

Configuración de peticiones del sistema

Control de los detalles de la respuesta

Respuestas concisas y conversacionales:

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.

Respuestas detalladas y exhaustivas:

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.

Reflejo de idiomas

Nova puede reconocer y responder en el idioma que habla el usuario. Utilice esta petición para mantener la coherencia del 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.

Concordancia de género para idiomas con géneros

Algunos idiomas requieren una concordancia de género en los verbos, adjetivos o pronombres cuando el asistente se describe. Para estos idiomas, especifique el género del asistente en la petición del sistema para que coincida con la voz seleccionada.

Idiomas afectados: hindi, portugués, francés, italiano, español, ruso, polaco

Cuándo es importante la concordancia de género:

- Hindi: se necesita siempre, ya que los verbos se conjugan en primera persona según el género del hablante.
- Portugués y francés: se necesita cuando se usan participios pasados o adjetivos (por ejemplo, en “Estou cansada/cansado”).
- Italiano y español: se necesita cuando se utilizan adjetivos para describirse (por ejemplo, en “Estoy/Sono contenta/contento”).

Implementación:

Incluya el identificador de género apropiado al principio de la petición del sistema en función de la voz que elija:

Para voces femeninas (kiara, carolina, ambre, beatrice, lupe, tiffany):

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

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

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

Ejemplos:

Hindi con voz femenina (kiara):

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

Resultado: "म अच्छी हूँ" (main achchhi hoon) frente a "म अच्छा हूँ" (main achchha hoon)

Italiano con voz masculina (lorenzo):

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

Resultado: "Sono contento" frente a "Sono contenta"

Cadena de pensamiento para el habla: razonamiento constitutivo

Utilice esta petición cuando desee que el modelo muestre su razonamiento para problemas complejos:

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

CONSTITUTION - REASONING

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

Nota: Si no desea que el modelo use el razonamiento para cada solicitud, puede agregar un par de ejemplos prácticos a la petición (consulte los ejemplos siguientes).

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 excesivo de frases sugeridas

Nova Sonic 2 es más sensible a las sugerencias de frases que Sonic 1. Este aumento de sensibilidad no es intrínsecamente bueno o malo, sino que depende del caso de uso. Si desea un estilo coherente y predecible, puede ser beneficioso. Sin embargo, si desea una variación más natural, las listas de frases explícitas pueden provocar un uso excesivo.

Si incluye peticiones con listas de frases explícitas, el modelo las utilizará con mucha frecuencia:

Ejemplo 1, frases de énfasis:

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."

Ejemplo 2, rellenos conversacionales:

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.

Recomendación:

- Si desea un estilo coherente: las listas de frases explícitas funcionan bien en Sonic 2 para crear respuestas predecibles y acordes con la marca.
- Si desea una variación natural: evite proporcionar listas de frases explícitas. Como alternativa, utilice orientación general como “habla de forma natural y conversacional” o proporcione ejemplos únicos.

Mejor enfoque, uso de ejemplos únicos:

En lugar de enumerar frases, proporcione 1 o 2 ejemplos que muestren el tono y el estilo deseados:

Tono natural y servicial

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 y directo

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.

Profesional con empatía

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, pero accesible

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.


Este enfoque muestra al modelo el comportamiento deseado sin provocar patrones de frases repetitivas mientras mantiene el control sobre el tono y el estilo.

Conceptos clave

Amazon Nova 2 Sonic utiliza una arquitectura de transmisión bidireccional con eventos estructurados para una IA conversacional en tiempo real. Comprender estos conceptos básicos es esencial para crear aplicaciones de voz eficaces.

Ciclo de vida de eventos

En el siguiente diagrama, se ilustra el ciclo de vida completo de eventos de transmisión bidireccionales:



El ciclo de vida de eventos de transmisión bidireccionales sigue un patrón estructurado desde el inicio de la sesión hasta la finalización de la conversación. Cada conversación incluye eventos de entrada (de la aplicación) y eventos de salida (de Amazon Nova 2 Sonic) que trabajan juntos para crear interacciones de voz naturales.

Secuencia de flujos de eventos

Una conversación típica sigue esta secuencia de eventos:

1. Inicio de la sesión: se inicializa la sesión de la conversación.
2. Petición del sistema: se envían las instrucciones del sistema.
3. Historial de chat (opcional): se proporciona el contexto de la conversación.
4. Fragmentos de audio: se transmite la entrada de audio del usuario.
5. Inicio de la finalización: la IA comienza el procesamiento.
6. Transcripciones de ASR (USUARIO): transcripción de la voz del usuario.
7. Uso de herramientas (opcional): la IA solicita la ejecución de herramientas.
8. Gestión de herramientas (opcional): se procesan y devuelven los resultados de las herramientas.
9. Transcripción (ASISTENTE), ESPECULATIVA: respuesta preliminar de la IA.
10. Fragmentos de audio: se transmite la salida de audio de la IA.
11. Transcripción (ASISTENTE), FINAL: transcripción final de la respuesta de la IA.
12. Audio de fin del contenido: marca el final del contenido de audio.
13. Fin de la petición: indica que se ha completado el procesamiento de la petición.
14. Fin de la sesión: se cierra la conversación.

Gestión de eventos de entrada con la API bidireccional

La API de transmisión bidireccional utiliza una arquitectura basada en eventos con eventos de entrada y salida estructurados. Comprender el orden correcto de los eventos es fundamental para implementar aplicaciones conversacionales que funcionen y mantener el estado de conversación adecuado durante todas las interacciones.

Descripción general

La conversación de Nova Sonic sigue una secuencia de eventos estructurada. Se empieza por enviar un evento `sessionStart` que contenga los parámetros de configuración de la inferencia,

como la temperatura y los límites de tokens. A continuación, se envía `promptStart` para definir el formato de salida de audio y las configuraciones de las herramientas, y se asigna un identificador único `promptName` que se debe incluir en todos los eventos posteriores.

Para cada tipo de interacción (petición del sistema, audio, etc.), se sigue un patrón de tres partes: se utiliza `contentStart` para definir el tipo de contenido y el rol del contenido (SYSTEM, USER, ASSISTANT, TOOL, SYSTEM_SPEECH), luego se proporciona el evento de contenido real y se termina con `contentEnd` para cerrar ese segmento. El evento `contentStart` especifica si se están enviando los resultados de la herramienta, si se está transmitiendo audio o una petición al sistema. El evento `contentStart` incluye un identificador único `contentName`.

Historial de la conversación

El historial de conversaciones solo se puede incluir una vez, después de darle la petición al sistema y antes de que comience la transmisión de audio. Sigue el mismo patrón `contentStart/textInput/contentEnd`. Los roles USER y ASSISTANT deben definirse en el evento `contentStart` para cada mensaje histórico. Esto proporciona un contexto esencial para la conversación actual, pero debe completarse antes de que comience cualquier nueva entrada del usuario.

Transmisión de audio

La transmisión de audio funciona con un muestreo continuo del micrófono. Tras enviar un `contentStart` inicial, se capturan las tramas del audio (aproximadamente de 32 ms cada una) directamente desde el micrófono y se envían inmediatamente como eventos `audioInput` utilizando el mismo `contentName`. Estas muestras de audio deben transmitirse en tiempo real a medida que se capturan, manteniendo la cadencia de muestreo natural del micrófono durante toda la conversación. Todas las tramas de audio comparten un único contenedor de contenido hasta que la conversación finaliza y se cierra explícitamente.

Cierre de la sesión


Una vez que la conversación finalice o deba terminarse, es esencial cerrar correctamente todas las transmisiones abiertas y finalizar la sesión en la secuencia correcta. Para finalizar correctamente una sesión y evitar la pérdida de recursos, se debe seguir una secuencia de cierre específica:

- Cierre todas las transmisiones de audio abiertas con el evento `contentEnd`.
- Envíe un evento `promptEnd` que haga referencia al `promptName` original.

- Envíe el evento `sessionEnd`.

Omitir cualquiera de estos eventos de cierre puede provocar conversaciones incompletas o recursos huérfanos.

Estos identificadores crean una estructura jerárquica: el `promptName` une todos los eventos de la conversación, mientras que cada `contentName` marca los límites de bloques de contenido específicos. Esta jerarquía garantiza que el modelo mantenga el contexto adecuado durante toda la interacción.



Flujo de eventos de entrada

En esta sección, se proporciona la estructura del flujo de eventos de entrada.

1. RequestStartEvent (inicio de la sesión)

El evento de inicio de la sesión inicializa la conversación con la configuración de inferencias y de detección de turnos.

Configuración de inferencias:

- `maxTokens`: número máximo de tokens que se generarán en la respuesta
- `topP`: parámetro de muestreo del núcleo (de 0,0 a 1,0) para el control de la aleatoriedad

- **temperature**: control de la asignación al azar en la generación (de 0,0 a 1,0)

Configuración de detección de turnos: el parámetro **endpointingSensitivity** controla la rapidez con la que Nova Sonic detecta cuándo ha terminado de hablar un usuario.

- **HIGH**: detecta las pausas rápidamente, lo que permite respuestas más rápidas, pero puede interrumpir a hablantes más lentos.
- **MEDIUM**: tiene una sensibilidad equilibrada para la mayoría de los escenarios de conversación (se recomienda de forma predeterminada).
- **LOW**: espera más tiempo antes de detectar el final del habla, lo que es mejor para hablantes reflexivos o indecisos.

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

Ejemplo:

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



```

    }
  }
}

```

2. PromptStartEvent

El evento de inicio de la petición define la configuración de la conversación, lo que incluye los formatos de salida, la selección de voz y las herramientas disponibles.

Para obtener una lista de los ID de voz disponibles, consulte [Soporte lingüístico y capacidades multilingües](#).

```

{
  "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

El evento de inicio del contenido de texto se utiliza para las peticiones del sistema, el historial de conversaciones y la entrada de texto multimodal.

Parámetro interactivo:

- `true`: habilita la entrada multimodal, lo que permite enviar mensajes de texto durante una sesión de voz activa
- `false`: entrada de texto estándar para las peticiones del sistema y el historial de conversaciones

Tipos de roles:

- SYSTEM: peticiones e instrucciones del sistema
- USER: mensajes del usuario en el historial de conversaciones o la entrada multimodal
- ASSISTANT: respuestas del asistente en el historial de conversaciones
- SYSTEM_SPEECH: controla el formato de transcripción para cambios de código en hindi (alfabetos latino, devanagari o mixto)

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

```

    }
  }
}

```

Ejemplo, petición del sistema:

```

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

```

Ejemplo, entrada multimodal:

```

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

```

Audio

```

{

```

```

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

```

Herramienta

```

{
  "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": {}
  }
}
```

Gestión de eventos de salida con la API bidireccional

Cuando el modelo Amazon Nova Sonic responde, sigue una secuencia de eventos estructurada. El flujo comienza con un evento `completionStart` que contiene identificadores únicos, como `sessionId`, `promptName` y `completionId`. Estos identificadores son coherentes a lo largo del ciclo de respuesta y unen todos los eventos de respuesta posteriores.

Descripción general

Cada tipo de respuesta sigue un patrón coherente de tres partes: `contentStart` define el tipo y el formato del contenido, el evento de contenido real, y `contentEnd` cierra ese segmento. La respuesta suele incluir varios bloques de contenido en secuencia: transcripción de reconocimiento automático de voz (ASR) (lo que dice el usuario), uso de herramientas opcional (cuando se necesita información externa), respuesta en texto (lo que el modelo planea decir) y respuesta en audio (la salida hablada).

Tipos de contenido de la respuesta

Transcripción de ASR

La transcripción de ASR aparece primero, haciendo que el modelo comprenda la voz del usuario con `role: "USER"` y `"additionalModelFields": "{\\"generationStage\\":\\"FINAL\\"}"` en el `contentStart`.

Uso de herramientas

Cuando el modelo necesita datos externos, envía eventos relacionados con herramientas con nombres y parámetros específicos de las herramientas.

Respuesta de texto

La respuesta en texto proporciona una vista previa del habla planificada con `role: "ASSISTANT"` y `"additionalModelFields": "{\\"generationStage\\":\\"SPECULATIVE\\"}"`.

Respuesta de audio

A continuación, la respuesta en audio entrega fragmentos de voz codificados en base64 que comparten los mismos `contentId` a lo largo de la transmisión.

Soporte de interrupciones

Durante la generación de audio, Amazon Nova Sonic permite un flujo de conversación natural a través de su capacidad de interrupción. Cuando un usuario interrumpe a Amazon Nova Sonic mientras está hablando, Nova Sonic deja de generar voz inmediatamente, pasa al modo de escucha y envía una notificación de contenido que indica que se ha producido una interrupción. Como Nova Sonic funciona más rápido que en tiempo real, es posible que parte del audio ya se haya entregado, pero aún no se haya reproducido. La notificación de interrupción permite que la aplicación del cliente borre la cola de audio y detenga la reproducción inmediatamente para crear una experiencia de conversación receptiva.

Transcripción final

Una vez finalizada la generación del audio (o interrumpida), Amazon Nova Sonic proporciona una respuesta en texto adicional que contiene una transcripción a nivel de frase de lo que realmente se ha dicho. Esta respuesta en texto incluye un evento `contentStart` con `role: "ASSISTANT"` y `"additionalModelFields": "{\\"generationStage\\":\\"FINAL\\"}"`.

Seguimiento de uso


Durante la gestión de las respuestas, se envían eventos de `usageEvent` para rastrear el consumo de tokens. Estos eventos contienen métricas detalladas sobre los tokens de entrada y de salida (tanto de voz como de texto) y de sus totales acumulados. Cada `usageEvent` mantiene el mismo `sessionId`, `promptName` y el mismo `completionId` que otros eventos en el flujo de la conversación. En la sección de detalles se proporcionan tanto los cambios incrementales (`delta`)

como los totales acumulados del uso de tokens, lo que permite un seguimiento preciso del uso durante la conversación.

Finalización

El modelo envía un evento `completionEnd` con los identificadores originales y un `stopReason` que indica cómo terminó la conversación. Esta jerarquía de eventos garantiza que la aplicación pueda rastrear qué partes de la respuesta deben estar juntas y procesarlas en consecuencia, manteniendo el contexto de la conversación a lo largo de múltiples turnos.

El flujo de eventos de salida comienza al entrar en la fase de generación de respuestas. Comienza con el reconocimiento automático de voz, selecciona una herramienta para utilizarla, transcribe la voz, genera audio, finaliza la transcripción y termina la sesión.



Flujo de eventos de salida

En esta sección, se describe la estructura del flujo de eventos de salida.

1. UsageEvent

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



```

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

```

2. CompleteStartEvent

```

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

```

3. TextOutputContent

ContentStart

```

"event": {
    "contentStart": {
        "additionalModelFields": "{\\"generationStage\\":\\"FINAL\\"}" |
        "{\\"generationStage\\":\\"SPECULATIVE\\"}",
        "sessionId": "string", // unique identifier
        "promptName": "string", // same unique identifier from promptStart event
        "completionId": "string", // unique identifier
    }
}

```

```

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

```

TextOutput

```

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

```

ContentEnd

```

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

```

4. ToolUse

ContentStart

```

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

```

```

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

```

ToolUse

```

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

```

ContentEnd

```

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

```

5. AudioOutputContent

ContentStart

```

"event": {

```

```

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

```

AudioOutput

```

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

```

ContentEnd

```

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

```


6. CompletionEndEvent

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

Barge-in (Interrumpir)

La interrupción permite a los usuarios interrumpir al asistente de IA mientras habla, igual que en conversaciones humanas naturales. En lugar de esperar a que el asistente termine, los usuarios pueden intervenir con información nueva, corregir o aclarar su afirmación anterior, redirigir la conversación a un tema diferente o simplemente detener al asistente cuando hayan escuchado lo suficiente. Esto crea una experiencia de conversación más natural y receptiva.

En el siguiente diagrama, se ilustra el flujo completo de la conversación de interrupción:



Cómo gestiona Amazon Nova 2 Sonic las interrupciones

Amazon Nova 2 Sonic está diseñado para gestionar las interrupciones sin problemas. Cuando el usuario comienza a hablar durante una respuesta, el sistema deja de generar inmediatamente la respuesta actual, mantiene todo el contexto de la conversación, envía una señal de interrupción al cliente y comienza a procesar la nueva entrada del usuario.

Preservación del contexto: incluso cuando hay una interrupción, Nova Sonic recuerda lo que se dijo antes de esta, el tema que se está discutiendo, el historial de la conversación y cualquier contexto relevante de los turnos anteriores. Esto garantiza que la conversación siga siendo coherente y natural.

Requisitos de implementación del cliente

Si bien Amazon Nova 2 Sonic gestiona las interrupciones en el servidor, es necesario implementar una lógica del cliente para que la experiencia sea completa.

El desafío de las colas de audio: la generación de audio es más rápida que la velocidad de reproducción. Esto significa:

- Nova Sonic genera fragmentos de audio rápidamente.
- El cliente recibe estos fragmentos y los pone en cola.
- El cliente los reproduce a una velocidad de conversación normal.
- Cuando se produce una interrupción, el audio ya está en cola para su reproducción.

Lógica del cliente necesaria: la aplicación debe gestionar cuatro pasos clave.

1. **Detección de la señal de interrupción:** se escucha el evento de interrupción de Nova Sonic y se reacciona inmediatamente cuando se recibe.
2. **Detención de la reproducción actual:** se pausa el audio que se está reproduciendo actualmente y se detiene el audio que esté en mitad de la reproducción.
3. **Borrado de la cola de audio:** se eliminan todos los fragmentos de audio en cola y se descarta el audio almacenado en búfer de la respuesta interrumpida.
4. **Inicio del audio nuevo:** se comienza a reproducir el audio recién recibido y se reanuda el flujo de reproducción normal.

Control de los turnos

Los turnos son un aspecto fundamental de la conversación natural. Amazon Nova 2 Sonic proporciona un control detallado sobre cuándo es el turno de la IA para hablar a través del parámetro `turnDetectionConfiguration`. Esto le permite optimizar el flujo de la conversación para diferentes casos de uso, lo que equilibra la capacidad de respuesta con la precisión. El parámetro `endpointingSensitivity` controla la rapidez con la que Amazon Nova 2 Sonic detecta el final del turno de un usuario y comienza a responder. Esta configuración afecta tanto a la latencia de las respuestas como a la probabilidad de interrumpir a los usuarios que siguen hablando.

Configuración de la API

Configure la sensibilidad de la detección de turnos en el evento `sessionStart`:

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

Niveles de sensibilidad

El parámetro `endpointingSensitivity` acepta tres valores: ALTO, MEDIO y BAJO. Cada nivel equilibra la velocidad de la respuesta con el riesgo de interrumpir a los usuarios que siguen hablando.

ALTO

El tiempo de respuesta más rápido, optimizado para la latencia. Nova Sonic responde lo más rápido posible después de detectar el final del habla. Duración de la pausa: 1,5 segundos. Ideal para preguntas y respuestas rápidas, aplicaciones de comando y control e interacciones urgentes.

MEDIO

Enfoque equilibrado con un tiempo de respuesta moderado. Reduce los falsos positivos a la vez que mantiene la capacidad de respuesta. Duración de la pausa: 1,75 segundos. Ideal para conversaciones generales, servicio de atención al cliente con consultas complejas y conversaciones de varios turnos.

BAJA

El tiempo de respuesta más lento con la máxima paciencia. Nova Sonic espera la mayor cantidad de tiempo antes de responder, lo que minimiza las interrupciones de los usuarios que se detienen mientras piensan. Duración de la pausa: 2 segundos. Ideal para conversaciones reflexivas, usuarios de edad avanzada o con problemas del habla y para resolver problemas complejos.

Referencia de la duración de la pausa

Nivel de sensibilidad	Duración de la pausa (segundos)
Alto (rápido)	1.5
Medio	1,75
Bajo (lento)	~2,0

Entrada multimodal

Amazon Nova 2 Sonic ahora admite la entrada multimodal, lo que le permite enviar mensajes de texto además de la entrada de voz durante una sesión de conversación. Si bien la voz sigue siendo el principal modo de interacción, la entrada de texto ofrece flexibilidad en situaciones en las que escribir resulta más cómodo o apropiado.

Se requiere una transmisión continua: la entrada multimodal requiere una sesión de transmisión activa para funcionar correctamente. La sesión debe mantener una transmisión continua como una sesión de voz normal; de lo contrario, se aplicarán los tiempos de espera de sesión estándar y se terminará la conexión.

Los niveles de sensibilidad en la entrada de texto multimodal son útiles en situaciones como las siguientes:

- Integración de aplicaciones del cliente (web y móvil): permite a los usuarios interactuar con la aplicación mediante texto y voz, lo que ofrece experiencias multimodales fluidas.
- Caso de uso de “El modelo comienza”: se puede enviar un mensaje de texto inmediatamente después del inicio de la sesión para hacer la petición al modelo de que comience a hablar.
- Guía del modelo durante la llamada asíncrona a herramientas: cuando se desencadena un evento toolUse y el sistema comienza a procesar llamadas a herramientas, el cliente puede enviar un mensaje de texto a Sonic para que le dé una respuesta natural mientras espera, como, por ejemplo: “Espere un segundo mientras proceso la información. Mientras tanto, ¿hay algo más en lo que pueda ayudar?”.
- Integración de DTMF de telefonía: el cliente utiliza el teclado del teléfono para ingresar información confidencial (como números de tarjetas de crédito). Nota: Amazon Nova Sonic no procesa los tonos de DTMF de forma nativa. Para admitir la entrada de DTMF, el sistema debe detectar los tonos, convertirlos en texto (por ejemplo, “1234”) y enviarlos a Nova 2 Sonic.

Funcionamiento

La entrada multimodal utiliza una secuencia de tres eventos similar a la entrada de audio:

1. Evento de inicio del contenido: indica el comienzo de la entrada de texto.
2. Evento de entrada de texto: contiene el mensaje de texto real.
3. Evento de fin del contenido: indica que se ha completado la entrada de texto.

Los tres eventos deben usar los mismos promptName y contentName para mantener la secuencia. Se debe generar un nuevo UUID para contentName cada vez que envíe una entrada de texto para garantizar un seguimiento adecuado de la conversación de varios turnos.

Estructura de evento

1. Evento de inicio del contenido

Inicia la secuencia de entrada de texto con los detalles de configuración:

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

```
    "role": "USER",
    "type": "TEXT",
    "interactive": true,
    "textInputConfiguration": {
      "mediaType": "text/plain"
    }
  }
}
```

Parámetros clave:

- **promptName**: nombre de la petición de conversación (coherente a lo largo de la sesión)
- **contentName**: identificador único para esta entrada de texto (se genera un nuevo UUID para cada mensaje)
- **role**: establecido en "USER" para indicar la entrada del usuario
- **type**: establecido en "TEXT" para la entrada de texto
- **interactive**: establecido en true para habilitar el modo interactivo
- **mediaType**: establecido en "text/plain" para contenido de texto sin formato

2. Evento de entrada de texto

Incluye el contenido real del mensaje de texto:

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

Parámetros clave:

- **promptName**: debe coincidir con el valor del evento de inicio del contenido
- **contentName**: debe coincidir con el valor del evento de inicio del contenido
- **role**: cadena del mensaje de texto

3. Evento de fin del contenido

Indica que se ha completado la entrada de texto:

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

Parámetros clave:

- `promptName`: debe coincidir con el valor de los eventos anteriores
- `contentName`: debe coincidir con el valor de los eventos anteriores

Soporte lingüístico y capacidades multilingües

Amazon Nova 2 Sonic ofrece una amplia selección de voces en varios idiomas, lo que le permite crear aplicaciones de IA conversacional que resulten naturales y culturalmente apropiadas para sus usuarios. Cada idioma ofrece opciones de voz con un sonido femenino y masculino.

En la siguiente tabla, se enumeran todas las voces disponibles y sus correspondientes configuraciones regionales de idioma:

Idioma	Locale	ID de voz con sonido femenino	ID de voz con sonido masculino
English (EE. UU.)	en-US	tiffany	matthew
Inglés (Reino Unido)	en-GB	amy	-
Inglés (Australia)	en-AU	olivia	-
Inglés (India)	en-IN	kiara	arjun
Francés	fr-FR	ambre	florian

Idioma	Locale	ID de voz con sonido femenino	ID de voz con sonido masculino
Italiano	it-IT	beatrice	lorenzo
Alemán	de-DE	tina	lennart
Español (EE. UU.)	es-US	lupe	carlos
Portugués	pt-BR	carolina	leo
Hindi	hi-IN	kiara	arjun

Estructura de eventos con voces en la aplicación

Puede especificar el ID de voz en `audioOutputConfiguration` al iniciar una petición en el evento `promptStart`:

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

Soporte multilingüe

Amazon Nova 2 Sonic ofrece potentes capacidades multilingües que permiten mantener conversaciones naturales en varios idiomas. El servicio admite voces políglotas (que hablan varios idiomas) y el cambio de código (mezcla de idiomas en la misma frase), lo que le permite crear aplicaciones conversacionales verdaderamente globales.

TIFFANY (en-US, femenina) y MATTHEW (en-US, masculina) son voces políglotas únicas que pueden hablar todos los idiomas disponibles:

1. Inglés
2. Francés
3. Italiano
4. Alemán
5. Español
6. Portugués
7. Hindi

Esto hace que Tiffany y Matthew sean ideales para aplicaciones que necesitan cambiar entre varios idiomas sin problemas.

Administración del historial del chat


Las respuestas de Amazon Nova 2 Sonic incluyen transcripciones de ASR (reconocimiento de voz automático) para las voces de los usuarios y los asistentes. Guardar el historial del chat es una práctica recomendada, no solo para registrarlo, sino también para reanudar las sesiones cuando la conexión se cierra inesperadamente. Esto permite al cliente enviar el contexto a Nova Sonic para continuar la conversación sin problemas.

Consulte los siguientes recursos para obtener más información sobre cómo administrar el historial del chat:

1. [Registro del historial del chat](#)
2. [Reanudación de conversaciones](#)

Envío del historial del chat

El historial de conversaciones solo se puede incluir una vez, después de la petición del sistema o la voz y antes de que comience la transmisión de audio. El historial del chat general no puede superar los 40 KB. En el siguiente diagrama, se muestra cuándo se transfiere el historial del chat durante el ciclo de vida del evento:



Cada mensaje histórico requiere tres eventos: `contentStart`, `textInput` y `contentEnd`.

Esquema de eventos por mensaje:

- `contentStart`: define el rol y la configuración del mensaje

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

- `textInput`: incluye el contenido real del mensaje. Una `textInput` no puede superar 1 KB. Si es así, divídalo en varias `textInputs` en el mismo bloque de contenido. Si la conversación supera los 40 KB, recorte el historial del chat general.

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

- `contentEnd`: marca el final del mensaje.

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

```
}  
}
```

Repita estos tres eventos para cada mensaje del historial del chat con alternancia entre los roles USUARIO y ASISTENTE.

Consideraciones importantes:

- El historial del chat solo se puede incluir una vez por sesión.
- El historial del chat debe enviarse después de la petición del sistema y antes de que comience la transmisión de audio.
- Todos los mensajes históricos deben enviarse antes de iniciar la transmisión de audio.
- Cada mensaje debe especificar el rol USUARIO o ASISTENTE.
- Utilice el contenido de la transcripción almacenado de los eventos de textOutput como valor de contenido en textInput.

Recepción de transcripciones de ASR

Durante una conversación, Amazon Nova 2 Sonic envía transcripciones de ASR a través de eventos de salida. Cada transcripción se entrega como una secuencia de tres eventos: contentStart, textOutput, and contentEnd.

Ejemplo, transcripción de la voz del usuario:

1. contentStart, indica el inicio de una transcripción:

```
{  
  "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"  
    },  
    "textOutput": {  
      "content": "transcripción de la voz del usuario"  
    },  
    "contentEnd": {}  
  }  
}
```



```
}  
}  
}
```

2. `textOutput`, incluye el contenido real de la transcripción:

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

3. `contentEnd`, marca el final de la transcripción:

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

El mismo patrón de tres eventos se aplica a los roles `USUARIO` y `ASISTENTE`. Extraiga el campo `content` del evento `textOutput` y el campo `role` del evento `contentStart` para crear el historial del chat.

Prácticas recomendadas

Almacene siempre el historial del chat para habilitar lo siguiente:

- Reanudaciones de sesiones en diferentes dispositivos
- Registro y auditoría de conversaciones
- Conservación del contexto para las interacciones de seguimiento

Importante: Al guardar el historial del chat, utiliza salidas de texto en función de su `generationStage`:

- Especulativa: un adelanto de lo que Nova 2 Sonic planea decir, se genera antes de que comience la síntesis de audio
- Final: la transcripción real por frase de lo que se dijo en la respuesta de audio

Guarde siempre la salida de texto FINAL en el historial del chat, ya que representa el registro exacto de la conversación.

Ejemplo de salida FINAL (guárdela en el historial del chat):

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

Ejemplo de salida ESPECULATIVA (vista previa opcional, no para el historial):

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

Configuración de herramientas

Amazon Nova 2 Sonic admite el uso de herramientas (también conocido como llamada a funciones), lo que permite al modelo solicitar información o acciones externas durante las conversaciones, como


llamadas a la API, consultas a bases de datos o funciones de código personalizadas. Esto permite que el asistente de voz tome medidas, recupere información e integre servicios externos en función de las solicitudes de los usuarios.

Nova 2 Sonic incluye llamadas asíncronas a las herramientas, lo que permite a la IA seguir conversando de forma natural mientras las herramientas se ejecutan en segundo plano, lo que crea una experiencia de usuario más fluida y con mayor capacidad de respuesta.

A continuación se muestran pasos simplificados sobre cómo usar las herramientas:

1. Definición de herramientas: especifique las herramientas disponibles con sus parámetros en el evento `promptStart`.
2. Habla del usuario: el usuario hace una solicitud que requiere una herramienta (por ejemplo, “¿Qué tiempo hace en Seattle?”).
3. Invocación de la herramienta: Nova 2 Sonic reconoce la necesidad y envía un evento `toolUse`.
4. Ejecución de la herramienta: la aplicación ejecuta la herramienta y devuelve los resultados.
5. Generación de la respuesta: Nova 2 Sonic incorpora los resultados en su respuesta hablada.

En el siguiente diagrama, se ilustra cómo funciona el uso de herramientas:



Definición de herramientas

Las herramientas se definen con un esquema JSON que describe su propósito, los parámetros y las entradas esperadas.

A continuación se muestran los componentes y las explicaciones de la definición de herramientas:

- **Nombre:** identificador único para la herramienta (utilice `snake_case`)
- **Descripción:** explicación clara de lo que hace la herramienta, ayuda a la IA a decidir cuándo utilizarla
- **InputSchema:** esquema JSON que define los parámetros que acepta la herramienta
- **Propiedades:** parámetros individuales con tipos y descripciones
- **Obligatorio:** conjunto de nombres de parámetros que se deben proporcionar

Ejemplo de definición de herramientas

A continuación se muestra una definición sencilla de una herramienta de meteorología

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

```
}
```

Configuración de herramientas en PromptStart

La configuración de herramientas se pasa a Nova 2 Sonic en el evento `promptStart` junto con la configuración de la salida de audio y 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": {}
  }
}

```

Parámetros de elección de herramientas

Nova 2 Sonic admite tres parámetros de elección de herramientas para controlar cuándo y qué herramientas se utilizan. Especifique el parámetro `toolChoice` en la configuración de herramientas:

- **Automático (predeterminado):** el modelo decide si se necesita alguna herramienta y puede llamar a varias herramientas si es necesario. Ofrece la máxima flexibilidad.
- **Cualquiera:** garantiza que se llame al menos a una de las herramientas disponibles al inicio de la respuesta, pero el modelo seleccionará la más adecuada. Útil cuando tiene varias bases de conocimiento o herramientas y quiere asegurarse de que se utilice una.
- **Herramienta:** obliga a llamar exactamente una vez a una herramienta específica al inicio de la respuesta. Por ejemplo, si especifica una herramienta de base de conocimiento, el modelo la consultará antes de responder, independientemente de si considera que es necesaria.

Ejemplos de elección de herramientas

Auto (valor predeterminado)

```

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

```

Cualquiera:

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

Herramienta específica:

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

Recepción y procesamiento de eventos de uso de herramientas

Cuando Amazon Nova 2 Sonic determina que se necesita una herramienta, envía un evento `toolUse` que contiene lo siguiente:

1. `toolUseID`: identificador único para la invocación de la herramienta
2. `ToolName`: nombre de la herramienta que se ejecutará
3. `Contenido`: cadena JSON que contiene los parámetros extraídos de la solicitud del usuario
4. `SessionID`: identificador de la sesión actual
5. `Rol`: establecido en “HERRAMIENTA” para los eventos de uso de herramientas

Ejemplo de evento de uso de herramientas

```
{  
  "event": {  
    "toolUse": {  
      "completionId": "<completion-id>",  
      "content": "{\"location\": \"Seattle\", \"units\": \"fahrenheit\"}",  
      "contentId": "<content-id>",  
      "promptName": "<prompt-id>",  
      "role": "T00L",  
      "sessionId": "<session-id>",  
      "toolName": "get_weather",  
      "toolUseId": "<tool-use-id>"  
    }  
  }  
}
```



```
}  
}
```

Pasos de procesamiento

1. Reciba el evento `toolUse` de Nova 2 Sonic.
2. Extraiga el nombre y los parámetros de la herramienta del evento.
3. Ejecute la lógica de la herramienta (llamada a la API, consulta a la base de datos, etc.).
4. Devuelva el resultado mediante un evento `toolResult`.

Ejemplo de evento ToolResult

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

Prácticas recomendadas

- **Descripciones claras:** escriba descripciones detalladas de las herramientas para ayudar a Nova 2 Sonic a entender cuándo se debe usar cada herramienta.
- **Validación de parámetros:** valide siempre los parámetros de la herramienta antes de la ejecución para evitar errores. Defina los parámetros de la herramienta con un esquema JSON adecuado con tipos de datos estructurados (como enumeraciones, números o booleanos) en lugar de cadenas abiertas siempre que sea posible.
- **Gestión de errores:** devuelve mensajes de error significativos en eventos `toolResult` cuando las herramientas fallan.
- **Ejecución asíncrona:** aproveche las llamadas asíncronas a las herramientas para mantener el flujo de la conversación.
- **Denominación de herramientas:** utilice nombres descriptivos y orientados a la acción (como `get_weather`, `search_database`, `send_email`).

Llamadas a herramientas asíncronas


A diferencia de las llamadas sincrónicas tradicionales entre herramientas, en las que la IA espera silenciosamente los resultados de las herramientas, el enfoque asíncrono de Amazon Nova 2 Sonic le permite:

- Continuar aceptando entradas del usuario mientras se ejecutan las herramientas
- Responder a nuevas preguntas sin esperar a que aparezcan los resultados pendientes de la herramienta
- Gestionar varias llamadas a herramientas simultáneamente
- Mantener un flujo de conversación natural sin pausas incómodas
- No es necesario realizar más configuraciones. La llamada a herramientas asíncrona funciona de forma inmediata.

Funcionamiento

Cuando Nova 2 Sonic hace una llamada a una herramienta, no detiene la conversación. En cambio, continúa escuchando y respondiendo de forma natural hasta que llega la herramienta.


Asynchronous Tool Calling Flow



Gestión de interrupciones del usuario

Si un usuario cambia su solicitud mientras se ejecuta una herramienta, Nova 2 Sonic la gestiona de forma inteligente sin cancelar las llamadas pendientes a la herramienta.

Async Tool Calling with User Interruption



Ejemplo de escenarios

```

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]
  
```

Funcionamiento

Los resultados de la herramienta siempre se entregan: cuando se completa una llamada a una herramienta, su resultado siempre se envía al modelo, incluso si el usuario ha cambiado la solicitud. El modelo utiliza sus capacidades de razonamiento para determinar cómo gestionar la información.

Procesamiento sensible al contexto: el modelo comprende el contexto de la conversación y puede gestionar adecuadamente los resultados de las herramientas desactualizadas. Por ejemplo:

- Si el usuario dice “gracias” después de cambiar de opinión, el modelo sigue necesitando los resultados originales para contextualizarlos.
- Si el usuario cambia su solicitud, el modelo puede reconocer los resultados originales y centrarse en la nueva solicitud.

Sin cancelación automática: el sistema no cancela ni ignora automáticamente las llamadas a las herramientas en función de las nuevas entradas del usuario. Esto garantiza que el modelo cuente con información completa para tomar decisiones inteligentes sobre cómo responder.

Integraciones

Amazon Nova 2 Sonic se puede integrar con varios marcos y plataformas para crear aplicaciones de IA conversacional. Estas integraciones proporcionan componentes prediseñados y API simplificadas para casos de uso comunes.

Strands Agents

Strands Agents es un SDK sencillo, pero potente, que adopta un enfoque basado en modelos para crear y ejecutar agentes de IA. Desde simples asistentes de conversación hasta complejos flujos de trabajo autónomos, desde el desarrollo local hasta la implementación en producción, Strands Agents se adapta a sus necesidades.

Para obtener una documentación completa sobre el marco de Strands, visite la [documentación oficial de Strands](#).

Strands BidiAgent proporciona una interacción de audio y texto en tiempo real a través de conexiones de transmisión persistentes. A diferencia de los patrones tradicionales de solicitud y respuesta, este agente mantiene conversaciones prolongadas y admite interrupciones, procesamiento simultáneo y respuestas de audio continuas.

Requisitos previos:

- Versión 3.8 o posterior de Python instalada
- Credenciales para AWS configuradas con acceso a Amazon Bedrock
- Conocimientos básicos sobre la sintaxis async/await de Python

Ejemplo de código:

Ejemplo de código

Instalación:

Instale los paquetes obligatorios:

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

Ejecute este ejemplo:

```
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. Importación: modelos obligatorios

```

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**: es la clase de agente principal que orquesta las conversaciones bidireccionales.
- **BidiAudioIO**: gestiona la entrada y la salida de audio para interacciones de voz.
- **BidiTextIO**: proporciona la salida de texto para transcripciones y respuestas.
- **BidiNovaSonicModel**: es el contenedor del modelo de Nova 2 Sonic.
- **Calculadora**: es una herramienta prediseñada para operaciones matemáticas.

2. Configuración de la E/S de audio y texto

```

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

```

BidiAudioIO administra la entrada del micrófono y la salida del altavoz, mientras que **BidiTextIO** muestra las transcripciones del texto y las respuestas en la consola.

3. Inicialización del modelo

```

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

```

Cree una instancia del modelo de Nova Sonic. El parámetro `region` especifica la región de AWS en la que se implementa el modelo.

4. Creación y ejecución del agente

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

El agente se crea con lo siguiente:

- Modelo: modelo de Nova 2 Sonic que se utilizará
- Herramientas: lista de herramientas a las que el agente puede llamar (por ejemplo, la calculadora)
- Entradas: entrada de audio del micrófono
- Salidas: salida de audio a los altavoces y salida de texto a la consola


Integraciones con marcos

Amazon Nova 2 Sonic se puede integrar con varios marcos y plataformas para crear aplicaciones de voz sofisticadas. En los siguientes ejemplos, se muestran los patrones de integración con marcos populares.

Amazon Bedrock AgentCore

Amazon Bedrock AgentCore proporciona un entorno de tiempo de ejecución administrado para implementar aplicaciones de Nova 2 Sonic con seguridad y escalabilidad empresariales. AgentCore simplifica la implementación de aplicaciones de IA de voz en tiempo real al gestionar la infraestructura, la autenticación y la conectividad de WebSocket.

AgentCore Architecture



Características clave:

- **Transmisión bidireccional:** soporte nativo para la interfaz de transmisión dúplex completa de Nova Sonic con procesamiento de eventos en tiempo real y comunicación de baja latencia.
- **Infraestructura de WebSocket:** servidores de WebSocket listos para producción con escalado automático, administración de conexiones y recuperación de errores.
- **Implementación de contenedores:** implemente aplicaciones de Nova Sonic como contenedores en una infraestructura administrada con escalado horizontal y control de versiones independiente.
- **Seguridad empresarial:** autenticación detallada mediante IAM y SigV4, aislamiento de VPC y registro de auditoría exhaustivo.

La arquitectura muestra cómo las aplicaciones cliente se conectan al Tiempo de ejecución de AgentCore a través de WebSocket con autenticación SigV4. El entorno en contenedores incluye el servidor de WebSocket, la lógica de la aplicación y el cliente de Nova Sonic, y todos se comunican con Nova Sonic a través de la API de transmisión bidireccional.

Ventajas:

- Operaciones simplificadas: céntrese en la lógica de la aplicación mientras AgentCore administra la infraestructura, el escalado y la fiabilidad.
- Seguridad empresarial: características integradas de autenticación, autorización y cumplimiento para las implementaciones de producción.
- Rentabilidad: pague solo por lo que use, con escalado automático y optimización de recursos.
- Productividad de los desarrolladores: reduzca el tiempo de producción con la infraestructura de WebSocket administrada y la implementación de contenedores.

Casos de uso


- Asistentes de voz de servicio al cliente con autenticación segura
- Aplicaciones de voz empresariales que requieren la integración de IAM
- Plataformas de voz multiusuario con implementaciones aisladas
- Aplicaciones habilitadas por voz que requieren registros de auditoría y cumplimiento

Para obtener documentación detallada sobre la implementación de Nova Sonic con AgentCore, visite la [documentación de Amazon Bedrock AgentCore](#).

LiveKit

LiveKit es una plataforma de código abierto para crear aplicaciones de audio y video en tiempo real. La integración con Amazon Nova 2 Sonic permite a los desarrolladores crear interfaces de voz conversacionales sin administrar complejas canalizaciones de audio ni protocolos de señalización.

Para obtener ejemplos detallados de implementación y ejemplos de código, visite la [documentación de integración de LiveKit con AWS](#).



Funcionamiento:

- **Capa del cliente:** las aplicaciones web, móviles o de escritorio se conectan mediante los SDK de cliente de LiveKit, que gestionan la captura de audio, la transmisión por WebRTC y la reproducción.
- **Servidor de LiveKit:** actúa como centro de comunicación en tiempo real mediante la gestión de conexiones WebRTC, el enrutamiento de transmisiones de audio y la gestión del estado de la sesión con una optimización de baja latencia.
- **Agente de LiveKit:** agente basado en Python que recibe el audio del servidor, lo procesa a través del complemento de Nova Sonic y transmite las respuestas de vuelta. Incluye características integradas, como la detección de actividad por voz y la administración de turnos.
- **Amazon Nova 2 Sonic:** procesa la transmisión de audio a través de la API de transmisión bidireccional, lleva a cabo el reconocimiento de voz, la comprensión del lenguaje natural y genera respuestas conversacionales con voz sintetizada.


Pipecat

Pipecat es un marco para crear aplicaciones de IA conversacional multimodal y de voz. Proporciona una arquitectura modular basada en canalizaciones que orquesta varios componentes para crear aplicaciones de voz inteligentes con Amazon Nova Sonic y otros servicios de AWS.

Para obtener ejemplos detallados de implementación y muestras de código, visite la [documentación de integración de Pipecat con AWS](#).

Características clave:

- Arquitectura de canalización: marco modular basado en Python para la composición de componentes de IA de voz, incluidos ASR, NLU, TTS, etc.
- Flujos de Pipecat: marco de administración de estados para crear una lógica conversacional compleja y ejecutar herramientas.
- Soporte de WebRTC: integración integrada con Daily y otros proveedores de WebRTC para la transmisión de audio en tiempo real.
- Integración con AWS: soporte nativo para Amazon Bedrock, Amazon Transcribe y Amazon Polly.



La arquitectura incluye:

- Transporte de WebRTC: transmisión de audio en tiempo real entre los dispositivos cliente y el servidor de aplicaciones.
- Detección de actividad de voz (VAD): VAD de Silero con detección de voz y supresión de ruido configurables.
- Reconocimiento de voz: Amazon Transcribe para una conversión de voz a texto precisa en tiempo real.
- Comprensión del lenguaje natural: Amazon Nova Pro en Bedrock con inferencia optimizada para la latencia.
- Ejecución de herramientas: flujos de Pipecat para la integración de las API y las llamadas al servicio de backend.
- Generación de respuestas: Amazon Nova Pro para respuestas coherentes y sensibles al contexto.

- Conversión de texto a voz: Amazon Polly con voces generativas para una salida de voz realista.


Implementación en AWS

Implemente sus aplicaciones de Nova Sonic en AWS con infraestructura como código con el AWS CDK (Cloud Development Kit). Este enfoque proporciona implementaciones repetibles, con control de versiones y con las prácticas recomendadas integradas.

Opciones de implementación

- Amazon ECS (Elastic Container Service): orquestación de contenedores completamente administrada con integración con el Equilibrador de carga de aplicación, escalado automático y ejecución de Fargate sin servidor.
- Amazon EKS (Elastic Kubernetes Services): Kubernetes administrado para una orquestación compleja, redes avanzadas, implementaciones en varias regiones y un amplio ecosistema de herramientas.
- AWS CDK: el AWS CDK le permite definir la infraestructura en la nube mediante lenguajes de programación conocidos.

Para obtener un ejemplo completo listo para producción de la implementación de Nova Sonic con el AWS CDK, consulte la [muestra del CDK de voz a voz](#) en GitHub. El siguiente ejemplo muestra:



- Configuración completa de la infraestructura del CDK con TypeScript
- Implementación del servidor de WebSocket para una comunicación en tiempo real
- Implementación de contenedores con ECS y Fargate
- Configuración del Equilibrador de carga de aplicación para soporte de WebSocket
- Configuración de grupos de seguridad y redes de VPC
- Supervisión y registros de CloudWatch
- Prácticas recomendadas para las implementaciones de producción


Sistemas multiagénticos

La arquitectura multiagente es un patrón muy utilizado para diseñar asistentes de IA que gestionan tareas complejas. En un asistente de voz con tecnología de Nova 2 Sonic, esta arquitectura coordina varios agentes especializados, donde cada agente opera de forma independiente para permitir el procesamiento paralelo, el diseño modular y las soluciones escalables.

Nova Sonic actúa como orquestador en un sistema multiagente y lleva a cabo dos funciones clave:

Administración del flujo de conversación: garantiza que se recopile toda la información necesaria antes de continuar con el siguiente paso de la conversación.

Clasificación de la intención: analiza las consultas de los usuarios y las dirige al subagente especializado correspondiente.



En el diagrama anterior, se muestra un asistente de voz bancario que utiliza una arquitectura multiagente. El flujo de la conversación comienza con un saludo y una recopilación del nombre del usuario, y luego gestiona las consultas relacionadas con la banca o las hipotecas a través de subagentes especializados.

Ejemplo de flujo de conversación:

1. El usuario se conecta al asistente de voz.
2. Nova 2 Sonic: “¡Hola! ¿Cómo se llama?”
3. Usuario: “Me llamo John”
4. Nova 2 Sonic: “Hola, John: ¿en qué puedo ayudarlo hoy?”
5. Usuario: “Quiero comprobar el saldo de mi cuenta”
6. Nova 2 Sonic: [dirige al agente de autenticación]
7. Agente de autenticación: “Proporcione su ID de cuenta”
8. Usuario: “12345”

9. Agente de autenticación: [verifica la identidad]

10 Nova 2 Sonic: [dirige al agente bancario]

11 Agente bancario: “Su saldo actual es de 5431,10 USD”

Si bien en este ejemplo se muestra cómo los subagentes utilizan el marco Strands Agents implementado en Amazon Bedrock AgentCore, la arquitectura es flexible. Puede elegir:

- Su marco de agentes preferido
- Cualquier proveedor de LLM
- Opciones de alojamiento personalizadas
- Diferentes patrones de orquestación

Ventajas:

- Modularidad: cada agente se centra en un dominio específico, lo que facilita el mantenimiento y la actualización del sistema.
- Escalabilidad: agregue nuevos agentes sin modificar los existentes, lo que permitirá que su sistema crezca a la par de sus necesidades.
- Procesamiento paralelo: varios agentes pueden trabajar simultáneamente, lo que mejora los tiempos de respuesta para consultas complejas.
- Especialización: cada agente se puede optimizar para su tarea específica mediante las herramientas y bases de conocimiento más adecuadas.
- Aislamiento de errores: si un agente falla, otros continúan funcionando, lo que mejora la fiabilidad general del sistema.

Consulte [este blog](#) para obtener más detalles y ejemplos de código.

Visite el [laboratorio multiagente del taller de Nova Sonic](#) para obtener ejemplos prácticos.

Integración de telefonía

Amazon Nova 2 Sonic se integra con los proveedores de telefonía para permitir el acceso a las aplicaciones de voz basadas en IA mediante llamadas telefónicas. En esta guía, se cubre la integración con Twilio, Vonage y otros sistemas basados en SIP para crear soluciones de centros de contacto y agentes de voz.

Twilio: plataforma de comunicaciones en la nube con capacidades programables de transmisión de voz y multimedia.

Vonage: API de comunicaciones globales con voz, transmisión de audio por WebSocket y conectividad SIP.

AWS proporciona un ejemplo completo de implementación que muestra a Nova Sonic en un entorno de centro de contacto con integración de telefonía y análisis en tiempo real.

Repositorio: [muestra de centro de contacto de Sonic con telefonía](#)

Sistemas avanzados con Amazon Nova

Descripción general

En esta sección, se proporciona una guía completa para usuarios avanzados que implementan patrones avanzados con modelos de Nova. Estas capacidades permiten aplicaciones sofisticadas, como la integración de herramientas, la generación aumentada por recuperación (RAG) y los agentes de IA autónomos.

Pensamiento extendido en Amazon Nova 2

Amazon Nova 2 Lite presenta capacidades de pensamiento extendido que permiten al modelo hacer un razonamiento más profundo para problemas complejos. Esta característica opcional le permite controlar cuándo y cómo el modelo asigna recursos computacionales adicionales para analizar tareas difíciles.

Cómo funciona el pensamiento extendido

Amazon Nova 2 presenta el pensamiento extendido como una capacidad híbrida. Usted tiene el control total:

- Pensamiento extendido desactivado (predeterminado): Amazon Nova 2 funciona con un razonamiento latente eficiente, óptimo para tareas diarias y aplicaciones de gran volumen.
- Pensamiento extendido activado: Amazon Nova 2 utiliza el razonamiento explícito y paso a paso, ideal para problemas complejos que requieren un análisis profundo.

Esfuerzo de razonamiento

A continuación se muestran los diferentes niveles de esfuerzo de razonamiento.

Esfuerzo bajo (`maxReasoningEffort`: "bajo")

Ideal para: tareas con mayor complejidad que requieren un pensamiento estructurado. Por ejemplo, puede utilizarlo para hacer sugerencias de revisión y mejora del código en las que el modelo deba tener en cuenta detenidamente la calidad del código existente, llevar a cabo tareas de análisis que requieran tener en cuenta detenidamente varios factores o situaciones de resolución de problemas que se beneficien de un enfoque metódico. El esfuerzo bajo es ideal para tareas complejas en las

que el razonamiento básico mejore la precisión sin requerir una planificación profunda de varios pasos.

Esfuerzo medio (maxReasoningeffort:"medio")

Ideal para: tareas de varios pasos y flujos de trabajo de codificación. Por ejemplo, puede utilizarlo para el desarrollo y la depuración de software cuando el modelo necesite comprender la estructura del código existente antes de implementar los cambios, la generación de código que requiere la coordinación entre varios archivos o componentes, los cálculos de varios pasos con interdependencias o la planificación de tareas con varias restricciones. Un esfuerzo medio es óptimo para flujos de trabajo agénticos que coordinan varias herramientas y requieren que el modelo mantenga el contexto en varias operaciones secuenciales.

Esfuerzo alto (maxReasoningeffort:"alto")

Ideal para: razonamiento STEM y resolución avanzada de problemas. Por ejemplo, puede utilizarlo para pruebas y problemas matemáticos avanzados que requieran una verificación minuciosa, tareas de análisis e investigación que requieran una investigación exhaustiva, diseños de sistemas complejos con consideraciones arquitectónicas en varias dimensiones o casos críticos de toma de decisiones con implicaciones significativas. Un esfuerzo alto proporciona la máxima precisión para tareas que requieran un razonamiento sofisticado, una evaluación cuidadosa de las alternativas y una validación exhaustiva de las conclusiones.

Inicio rápido: activación del pensamiento extendido

El pensamiento extendido se controla a través del parámetro `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"])

```

Parámetros de razonamiento:

- type: enabled o disabled (predeterminado: disabled)
- maxReasoningEffort: low, medium, o bien high

Note

Temperatura, TopP y TopK no se pueden usar con maxReasoningEffort establecido en high. Si se utilizan estos parámetros juntos, se producirá un error.

Para ver ejemplos completos de código que utiliza el pensamiento extendido, consulte [the section called “Biblioteca de códigos”](#).

Estructura de la respuesta

Al habilitar el pensamiento extendido, las respuestas incluyen bloques reasoningContent seguidos de bloques de contenido text:

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

Note

Con Amazon Nova 2, el contenido de razonamiento se muestra como [REDACTED]. Se le continuará cobrando por los tokens de razonamiento, ya que contribuyen a mejorar la calidad de la salida. Ahora incluimos este campo en la estructura de la respuesta para preservar la opción de exponer el contenido del razonamiento en el futuro. Estamos trabajando activamente con los clientes para determinar el mejor enfoque para dar a conocer el proceso de razonamiento del modelo. El contenido del razonamiento se muestra como [REDACTED]. Se le continuará cobrando por los tokens de razonamiento, ya que contribuyen a mejorar la calidad de la respuesta.

Opciones de configuración

Amazon Nova 2 presenta un nuevo parámetro `reasoningConfig` que puede agregar a la estructura de solicitudes de conversación existente para permitir el razonamiento:

```
additionalModelRequestFields={
  "reasoningConfig": {
```

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

Parámetros:

- tipo: cambie entre "enabled" y "disabled" (la opción predeterminada es "disabled")
- **maxReasoningEffort**: si está habilitado, controla la profundidad del razonamiento.
- “bajo”: tareas moderadamente complejas
- “medio”: problemas complejos que requieren un análisis sustancial
- “alto”: el razonamiento más completo para tareas muy complejas

Note

Al utilizar "high", temp, TopP y maxToken no deben estar configurados. En este modo, el modelo lleva a cabo un análisis más profundo para encontrar la mejor solución. Este procesamiento más exhaustivo puede generar una salida que supere los 65 000 tokens. La cantidad exacta depende de la complejidad de la solicitud, pero, para algunos problemas, hemos visto que puede llegar a 128 000 tokens. Esto garantiza que obtendrá un razonamiento completo y de alta calidad, en lugar de resultados truncados.

Modelos compatibles

El pensamiento extendido está disponible actualmente en: Amazon Nova 2 Lite (us.amazon.nova-2-lite-v1:0).

Pensamiento extendido con el uso de herramientas

El pensamiento extendido funciona a la perfección con las llamadas a herramientas, lo que permite a Amazon Nova razonar sobre qué herramientas utilizar y cómo interpretar sus resultados.

Descripción de los tokens de razonamiento y los precios

Tipos de token

Los tokens de pensamiento extendido se facturan como tokens de salida:

- Tokens de entrada: contenido original de la solicitud (precio de entrada estándar).
- Tokens de salida: incluye los tokens de razonamiento y el contenido final de la respuesta visible (precio de salida estándar).

Desglose de usos

Los tres tipos de token se incluyen en las métricas de uso y en la facturación. Los tokens de razonamiento tienen el mismo precio que los de salida y aparecerán como “REDACTADO” en la respuesta del modelo.

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

Preguntas frecuentes

¿Por qué Amazon Nova 2 Lite muestra “[REDACTADO]” para el contenido de razonamiento en lugar de mostrar el proceso de pensamiento del modelo?

Nuestro objetivo principal para este lanzamiento es asegurarnos de que Nova 2 ofrezca la mejor inteligencia de su clase para sus tareas, lo que se verá reflejado en la mejora de la precisión.

Reconocemos que la visibilidad del proceso de razonamiento es valiosa y hemos escuchado un gran interés por parte de los clientes por comprender cómo el modelo resuelve los problemas.

Estamos buscando formas de hacer que esté disponible pronto.

Se le continuarán facturando los tokens de razonamiento, ya que representan un trabajo real que mejora la calidad de la producción

que se capturará en outputTokens junto con los tokens de respuesta.

¿Cómo puedo saber si el pensamiento extendido funciona si el razonamiento está redactado?

Para confirmar si el pensamiento extendido funciona, puede comprobar si hay bloques `reasoningContent` en la salida de la respuesta (solo aparecen cuando el razonamiento está habilitado).

Uso de herramientas (llamada a funciones)

Las herramientas amplían las capacidades de Amazon Nova al conectar el modelo a funciones externas, como API, bases de datos y entornos de ejecución de código. El uso de herramientas permite a Amazon Nova acceder a información en tiempo real, hacer cálculos e interactuar con sistemas externos.

Descripción del flujo de trabajo del uso de herramientas

El uso de herramientas con Amazon Nova implica tres fases clave:

Consulta del usuario y definición de la herramienta

Para definir las herramientas, proporcione esquemas JSON que describan la funcionalidad y los requisitos de entrada de cada herramienta. La configuración de la herramienta debe incluir detalles explícitos sobre cuándo y cómo se debe utilizar cada herramienta.

Selección de herramientas

Cuando un usuario envía un mensaje, Amazon Nova lo analiza para determinar si necesita una herramienta. Esta elección automática de herramientas examina el contexto y decide qué herramienta (si hay alguna) se debe invocar. Si Amazon Nova identifica una herramienta adecuada, devolverá su nombre y los parámetros necesarios.

Usted es responsable de ejecutar la herramienta en función de la solicitud del modelo. Esto significa que escribirá el código que invoca la funcionalidad de la herramienta y procesa los parámetros de entrada proporcionados por el modelo.

Devolución de resultados

Después de ejecutar la herramienta, envíe los resultados a Amazon Nova en un formato estructurado mediante JSON o una combinación de texto e imágenes. Amazon Nova incorpora la salida de la herramienta en la respuesta final. Si se producen errores durante la ejecución, indíquelo en la respuesta de la herramienta para permitir que Amazon Nova lo ajuste en consecuencia.

Creación de una herramienta

Defina las herramientas mediante una configuración de herramientas que incluya una matriz de herramientas y, opcionalmente, un parámetro de elección de herramientas. Cada especificación de herramienta debe incluir lo siguiente:

- Nombre: identificador único para la herramienta
- Descripción: explicación concisa de la funcionalidad de la herramienta
- Esquema de entrada: esquema JSON que defina los parámetros obligatorios y opcionales

Example Ejemplo de configuración de herramientas

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

Prácticas recomendadas para definiciones de herramientas

- Asegúrese de que el nombre y la descripción coincidan de forma explícita con la funcionalidad exacta de la herramienta y evite las herramientas que sean demasiado similares semánticamente.

- Incluya los diferenciadores clave en la descripción para ayudar al modelo a distinguir entre herramientas similares.
- Limite los esquemas JSON a dos capas de anidación para obtener el mejor rendimiento.
- Restrinja las entradas mediante tipos de esquema (por ejemplo, enum, int, float) en lugar de describir la estructura en texto sin formato.
- Indique los parámetros obligatorios y opcionales mediante la notación de esquema JSON (por ejemplo, "required": ["param1", "param2"]).
- Valide el esquema JSON con un validador estándar antes de enviarlo.
- Coloque los argumentos de cadena larga al final del esquema y evite anidarlos.

Salida estructurada con decodificación restringida

Los modelos de Amazon Nova aprovechan la decodificación restringida para garantizar una alta fiabilidad en las salidas generadas. Esta técnica utiliza la gramática para restringir los posibles tokens en cada paso de generación, lo que evita que las claves no sean válidas y aplica los tipos de datos correctos en función del esquema definido.

Example Ejemplo de salida estructurada

```
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"}
}
}

```

Opciones de elección de herramientas

Amazon Nova admite tres parámetros de elección de herramientas:

Herramienta

Se llamará una vez a la herramienta, lo que es ideal para casos de uso de salidas estructuradas

Cualquiera

Se llamará a una de las herramientas proporcionadas al menos una vez, lo que es útil para escenarios de selección de API.

Auto

El modelo decide si llamar a una herramienta y a cuántas herramientas se llamará (comportamiento predeterminado).

Llamada a una herramienta

Cuando Amazon Nova decide llamar a una herramienta, devuelve un bloque de uso de herramientas como parte del mensaje del asistente con `stopReason` establecido en `"tool_use"`. El bloque de herramientas contiene el nombre de la herramienta y sus entradas.

Note

Ejecute las siguientes secciones de código secuencialmente (Llamada a una herramienta → Procesamiento de la llamada a la herramienta → Devolución de los resultados de la herramienta) en una sola sesión de Python. Para volver a ejecutar los ejemplos, reinicie la sesión de Python.

Example Llamada a una herramienta

```
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']}")

```

Procesamiento de llamadas a herramientas

Extraiga el nombre y los argumentos de la herramienta del mensaje y, a continuación, invoque la herramienta:

```

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"])

```

Devolución de los resultados de la herramienta

Devuelva los resultados de la herramienta con el 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}")

```

Gestión de errores

Informe de los errores a Amazon Nova para permitir la modificación de la solicitud y volver a intentarlo:

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

Consideraciones de seguridad

- Valide que las herramientas existan antes de invocarlas.
- Asegúrese de que las entradas estén formateadas correctamente.
- Compruebe que existan los permisos adecuados antes de ejecutar la herramienta.
- Confíe en los detalles de la sesión en lugar de permitir que Amazon Nova ingrese información del usuario en las llamadas a herramientas.
- Recuerde que los LLM pueden alucinar con las llamadas a herramientas, por lo que deberá validarlos siempre antes de ejecutarlos.

Herramientas del sistema integradas

Los modelos de Amazon Nova 2.0 incluyen herramientas integradas completamente administradas que no requieren una implementación personalizada. Habilite estas herramientas con un sencillo cambio en la API de Converse.

Code Interpreter

Intérprete de código permite a Nova poner en marcha código Python de forma segura en entornos de pruebas aislados. Esta herramienta está diseñada para cálculos matemáticos, operaciones lógicas y algoritmos iterativos.

Note

Code Interpreter está disponible en las regiones de AWS IAD, PDX y NRT. Para asegurarse de que las solicitudes se envíen a una región compatible, utilice CRIS global. Al utilizar claves de la API de Bedrock, tendrá que agregar manualmente los permisos `InvokeTool` a las definiciones de las políticas. El rol predeterminado de Bedrock no permite la acción `InvokeTool`.

Especifique el parámetro `systemTool` para habilitar Code Interpreter:

```
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"])
```

El intérprete ejecuta el código en un entorno de pruebas y devuelve el resultado en un esquema estándar:

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

Web Grounding

El Anclaje web permite a Amazon Nova acceder a información de Internet en tiempo real, lo que proporciona respuestas actualizadas y reduce las alucinaciones. Para habilitarlo, especifique la herramienta del sistema nova_grounding:

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

Para obtener información detallada sobre el Anclaje web, consulte [the section called “Web Grounding”](#).

Protocolo de contexto para modelos (MCP)

El protocolo de contexto para modelos (MCP) es un estándar abierto que permite las conexiones bidireccionales seguras entre orígenes de datos y herramientas basadas en IA. En lugar de crear adaptadores personalizados para cada API o servicio, ejecute un servidor MCP y deje que Amazon Nova detecte las herramientas automáticamente por medio de un puente cliente.

Una vez conectadas, Amazon Nova trata las herramientas MCP como cualquier otra integración externa: decide cuándo llamarlas, envía los parámetros obligatorios e incorpora los resultados en las respuestas. El uso de Amazon Nova con Strands facilita las cosas con un MCPClient integrado que administra automáticamente la detección, la conexión y la asignación de resultados.

Creación de agentes de IA

Los modelos de Amazon Nova están optimizados para crear agentes de IA con Amazon Nova Act. Los modelos proporcionan un mejor uso de las herramientas, un mejor razonamiento para tareas de varios pasos, una capacidad mejorada para mantener el contexto en los flujos de trabajo complejos de los agentes y compatibilidad con herramientas MCP remotas.

Creación de un agente

Los agentes de IA creados con Nova pueden orquestar varias llamadas a herramientas, mantener el contexto durante interacciones prolongadas y corregir el rumbo cuando sea necesario. El pensamiento extendido transforma los flujos de trabajo de los agentes al permitir el razonamiento sistemático a través de objetivos complejos. Considere la posibilidad de utilizar un SDK de marco de planificación, como Strands Agents, para reforzar el proceso de planificación y ejecución de los sistemas de agentes.

Patrones de diseño de agentes

Al diseñar agentes con Nova:

- Habilite el razonamiento medio o alto para obtener los mejores resultados en flujos de trabajo complejos de varios pasos que requieran planificación y verificación.
- Implemente una elección de herramientas auto para permitir una selección flexible de herramientas en todas las interacciones entre los agentes.

- Diseñe una gestión de errores que permita a los agentes recuperarse y volver a intentarlo con enfoques modificados.
- Mantenga el historial de conversaciones para conservar el contexto en todas las interacciones entre los agentes.
- Implemente mecanismos sólidos de filtrado y moderación del contenido en contenido no controlado que consume el sistema de agentes. Por ejemplo, Amazon ofrece Barreras de protección para Amazon Bedrock, una característica diseñada para aplicar barreras de protección en varios modelos fundacionales, bases de conocimiento y agentes. Estas barreras de protección pueden filtrar el contenido dañino, bloquear temas denegados y ocultar información confidencial, como la información de identificación personal.

Ejemplo de agente multiherramienta

```
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"
        # }
    # }
# }
)

```

Invocación de un agente

La invocación de un agente implica administrar el flujo de la conversación, procesar las llamadas a herramientas y mantener el estado en varias interacciones.

Transmisión de respuestas del agente

Transmita las respuestas para proporcionar visibilidad en tiempo real del razonamiento y las acciones del 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)

```

Administración del estado del agente

Mantenga el historial de conversaciones y los resultados de la herramienta para preservar el contexto. En el siguiente ejemplo, se muestra para un solo turno, pero el desarrollador puede

determinar cómo orquestar el sistema de agentes general en función de los requisitos del flujo de trabajo. Además, las herramientas de Amazon Web Services, como Strands, administran el contexto del agente y el estado de la herramienta en nombre del desarrollador.

```
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
#)
```

Prácticas recomendadas para agentes

Para obtener más información sobre las prácticas recomendadas para agentes, consulte [the section called “Prácticas recomendadas”](#).

Para obtener orientación sobre el desarrollo de agentes de IA conversacional, consulte [Voz a voz](#).

Web Grounding

El Anclaje web permite a Amazon Nova buscar información actual en Internet y proporcionar respuestas con citas. Esta característica resulta útil para consultas que requieren información actualizada más allá de los datos de entrenamiento del modelo.

Cómo funciona Web Grounding

Cuando se habilita Web Grounding para una petición, se llevan a cabo los siguientes pasos:

1. Solicitud de configuración: la aplicación envía una petición de usuario a la API de Amazon Bedrock con nova_grounding habilitado como systemTool.
2. Búsqueda y análisis: el modelo determina si se necesita una búsqueda, efectúa una o más búsquedas de información relevante y evalúa si se requieren búsquedas adicionales para ampliar su comprensión o profundizar en subtemas específicos.
3. Generación de respuestas: Amazon Nova sintetiza automáticamente la información de los resultados de búsqueda para generar una respuesta final de la API basada en información en tiempo real, con citas de los orígenes.

Cómo utilizar Web Grounding

Para obtener ejemplos completos de código que utiliza el Anclaje web, consulte la sección Muestras de código.

Para incluir el Anclaje web en los resultados, especifique el siguiente parámetro `systemTool` en el bloque `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)
```

Disponibilidad en las regiones

Actualmente, el Anclaje web solo está disponible en las regiones de EE. UU. y solo es compatible con los perfiles CRIS estadounidenses.

Estructura de una respuesta

A continuación, se muestra un ejemplo de respuesta. La respuesta se ha acortado por motivos de brevedad:

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

Cada cita incluye lo siguiente:

- `text`: segmento de la respuesta que generó el modelo.
- `citationsContent`: contenedor principal de los datos de la cita relacionados con un segmento del texto.
- `citations`: contenedor dentro de `citationsContent` que contiene la ubicación de una cita.
- `location`: contenedor dentro de `citations` que contiene el origen de una cita.
- `web`: contenedor dentro de `location` que contiene los detalles del origen web.
- `url`: dirección web completa (URL) del origen de la cita.
- `domain`: dominio raíz de la URL del origen.

Seguridad del anclaje

Sus datos nunca abandonan la infraestructura de AWS. Las consultas generadas por el modelo permanecen dentro de los servicios de AWS y nunca se envían al resto de Internet. Nuestro amplio índice interno de búsquedas en Internet y nuestros gráficos de conocimiento priorizan los orígenes fiables y de alta calidad, y filtran el contenido malicioso cuando ingresa. Por último, protegemos su aplicación contra la inyección de peticiones indirectas y la información errónea mediante el filtrado en tiempo de ejecución (tenga en cuenta que esta mitigación está limitada a los idiomas distintos del inglés).

Gestión de errores

No incluya una entrada de `toolSpec` con el nombre `nova_grounding`. Si se incluye una herramienta con este nombre, se producirá un error.

A continuación, se ofrece una lista de los posibles errores que se pueden producir al utilizar Web Grounding:

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

Permisos obligatorios para herramientas integradas

Tiene dos opciones para asegurarse de que el rol pueda acceder al Anclaje web en Amazon Bedrock:

1. Habilite `BedrockFullAccess` en el rol de IAM: si el rol posee `BedrockFullAccess`, dispondrá de acceso automático al Anclaje web.
2. Agregue permisos específicos (si es necesario): si necesita un control de acceso más detallado, agregue esta política a la política de IAM del rol y sustituya el ID de cuenta por su ID de Cuenta de AWS:

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

El Anclaje web tiene la clave de condición `aws:requestedRegion` configurada como “sin especificar”. Si sus políticas o políticas de control de servicios (SCP) actuales imponen esta condición, es posible que tenga problemas de acceso. Actualizar la condición para permitir una región solicitada “no especificada” puede resolver este problema.

 Note

Si habilita la herramienta Web Grounding, usted es responsable del uso que usted haga, y del uso que hagan los usuarios finales, de los resultados que incorporen información básica. Sabrá si su resultado incluye información fundamentada procedente de citas o enlaces al material fuente. Debe retener y mostrar estas citas y enlaces en el resultado que proporcione a sus usuarios finales.

 Note

Web Grounding tiene un costo adicional. Para obtener más información, consulte [Precios de AWS Bedrock](#).

Guía sobre ingeniería de peticiones

La ingeniería de peticiones es la práctica de diseñar instrucciones para comunicarse eficazmente con modelos de lenguaje de gran tamaño (LLM) como Amazon Nova. La ingeniería de peticiones le permite controlar el comportamiento del modelo, mejorar la calidad de la salida y crear aplicaciones fiables basadas en IA.

Una ingeniería de peticiones eficaz implica la creación de entradas que guíen a los modelos para producir las salidas deseadas. Una petición bien elaborada proporciona instrucciones claras, un contexto relevante y datos de entrada con el formato adecuado.

¿Qué es la ingeniería de peticiones?

La ingeniería de peticiones es la práctica de optimizar la entrada de texto en un modelo de lenguaje de gran tamaño (LLM) para mejorar el resultado y obtener las respuestas deseadas. Las peticiones ayudan a los LLM a realizar una amplia variedad de tareas, como la clasificación, la respuesta a preguntas, la generación de códigos, la redacción creativa y mucho más. La calidad de las peticiones que proporcione a los LLM puede afectar a la calidad de las respuestas del modelo. En esta sección se proporciona toda la información necesaria para comenzar con la ingeniería de peticiones. También incluye herramientas que le permitirán encontrar el mejor formato de petición posible para su caso de uso cuando utilice un LLM en Amazon Bedrock.

La eficacia de las peticiones depende de la calidad de la información proporcionada y de la elaboración de la propia petición. Las peticiones pueden incluir instrucciones, preguntas, detalles contextuales, entradas y ejemplos para guiar eficazmente el modelo y mejorar la calidad de los resultados. En este documento, se describen las estrategias y tácticas para optimizar el rendimiento de la familia de modelos de Amazon Nova 2 Sonic. Los métodos presentados en este documento pueden emplearse en varias combinaciones para amplificar su eficacia. Le animamos a que experimente para identificar los enfoques más adecuados para sus necesidades específicas.

Introducción a la ingeniería de peticiones

Antes de empezar con la ingeniería de peticiones, le recomendamos que cuente con los siguientes elementos para que pueda desarrollar de forma iterativa la petición óptima para su caso de uso:

Definición del caso de uso

Defina su caso de uso en cuatro dimensiones:

- **Tarea:** defina qué quiere que haga el modelo. Esto determina la técnica de petición correcta.
- **Rol:** defina el rol que el modelo debe adoptar para llevar a cabo la tarea. Los modelos de Amazon Nova admiten tres roles (sistema, usuario o asistente).
- **Estilo de respuesta:** defina la estructura o el estilo de respuesta que debe seguir el modelo en función de la audiencia, como JSON, Markdown o conversacional.
- **Instrucciones:** defina el conjunto de instrucciones que el modelo debe seguir para cumplir con los criterios de éxito.

Establecimiento de los criterios de éxito

Defina los criterios de éxito o las métricas de evaluación. Puede proporcionar una lista de criterios o proporcionar métricas de evaluación específicas, como la longitud, la puntuación BLEU, ROUGE, el formato, la realidad y la fidelidad.

Redacción de una petición

Cree una petición inicial que incorpore la tarea, el rol, el estilo de respuesta e instrucciones. Itere en función de los resultados.

La eficacia de las peticiones depende de la calidad de la información que proporcione.

Prácticas recomendadas generales

Las siguientes prácticas recomendadas se aplican principalmente a los modelos de texto de Amazon Nova, pero puede aplicarlas a otros modelos, además de las prácticas recomendadas específicas de cada modalidad.

Para obtener más información sobre cómo hacer peticiones de entradas multimodales, consulte [Peticiones de entradas multimodales](#). Para obtener información sobre cómo hacer peticiones de entradas de voz, consulte [Peticiones de conversación de voz](#).

Descripción de los roles

Los modelos de Amazon Nova le permiten estructurar peticiones mediante el uso de tres roles distintos: sistema, usuario y asistente.

- **Sistema (opcional):** aunque no es obligatorio, establece los parámetros de comportamiento generales del asistente. También se puede utilizar para proporcionar instrucciones y directrices adicionales que el usuario desee que el modelo siga a lo largo de la conversación.

- Usuario: opcionalmente, puede incluir el contexto, las tareas, las instrucciones y el resultado deseado junto con la consulta del usuario.
- Asistente: ayuda a guiar al modelo hacia la respuesta deseada.

Temas

- [Creación de peticiones precisas](#)
- [Enfoque a secciones de la petición](#)
- [Uso del rol del sistema](#)
- [Cómo proporcionar ejemplos \(petición con pocos pasos\)](#)
- [Sistemas de llamadas a herramientas](#)
- [Técnicas de peticiones avanzadas](#)

Creación de peticiones precisas

La elaboración de consultas de usuario específicas es crucial en la ingeniería de peticiones. Las consultas bien armadas guían a los modelos de comprensión de texto de Amazon Nova para generar respuestas precisas y pertinentes. Para elaborar dichas consultas, es esencial empezar por proporcionar información contextual. El contexto proporcionado ayuda a situar mejor el modelo al alinearlos con escenarios claros para el usuario objetivo, lo que mejora la relevancia y la coherencia del resultado.

Cómo proporcionar información contextual y específica

Los modelos funcionan mejor si las instrucciones son claras, bien estructuradas, breves y específicas. Esta guía de plantillas de peticiones se aplica tanto a peticiones del usuario como del sistema.

Plantilla de petición

```
# 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}"""

```

Ejemplo: Información específica y contextual

A continuación, se muestra un ejemplo de una petición que se reescribe con información específica y contextual. Añadir más información contextual ayuda al modelo a orientarse hacia el comportamiento deseado.

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]

- Sea claro: al hacerle peticiones al modelo, trate de mantener las instrucciones lo más claras posible de manera que un humano las pueda entender en lugar de una máquina (por ejemplo, una lista al estilo JSON).
- Sea específico: dé al modelo instrucciones específicas sobre cuál es la tarea, cuál es el resultado esperado y cualquier contexto adicional para ayudarlo a responder de la manera que usted desea.

Especificación del formato y el estilo de la salida

Si desea que Amazon Nova 2 genere respuestas que se adapten a sus necesidades específicas, puede especificar el formato y el estilo de la salida. Por ejemplo, si quiere generar respuestas solo en JSON o restringir la longitud de la respuesta a un número máximo de palabras, viñetas o párrafos. Esto permite a Amazon Nova 2 comprender mejor sus requisitos y producir una salida más relevante y fácil de analizar.

Utilice mayúsculas y palabras contundentes como HAZ, NO HAGAS o DEBES para enfatizar las reglas que desea que el modelo obedezca estrictamente. Por ejemplo, si desea incluir solo un objeto

JSON en la respuesta, puede indicárselo al modelo diciendo “DEBES responder solo en formato JSON. NO utilices ningún otro formato al responder a la pregunta”.

Estos son algunos ejemplos de peticiones que se reescriben con información específica y contextual. Añadir más información contextual ayuda al modelo a orientarse hacia el comportamiento deseado.

Ejemplo 1: Cómo proporcionar detalles adicionales

Agregar detalles adicionales sobre el formato de la respuesta puede ayudar al modelo a lograr el resultado deseado. Algunos de los otros formatos de respuesta comúnmente utilizados incluyen CSV, Markdown, YAML y 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
` ``

```

## Ejemplo 2: Cómo proporcionar restricciones de estilo

En este caso, la petición con restricciones de estilo proporciona información completa sobre las restricciones que se deben seguir y el formato de respuesta deseado. Como se observa en la respuesta, la petición optimizada se ajusta mejor a la brevedad solicitada y a la estructura de lista con viñetas.

### 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.

## Ejemplo 3: Cómo limitar el formato de respuesta

En este caso, la petición con el formato de respuesta obliga al modelo a responder solo con el número de categoría y a limitarlo a entre 1 y 10, en lugar de ser muy detallado.

## 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

## Cómo proporcionar secciones claras en la petición

Más allá del contexto inicial, un formato de consulta estructurado desempeña un papel importante a la hora de optimizar las interacciones con el modelo de lenguaje. Separar las distintas partes de la entrada con delimitadores garantiza la claridad y mejora la capacidad de los modelos de Amazon Nova 2 para comprender la estructura de la consulta. Otra forma eficaz es utilizar listas numeradas o viñetas, que pueden ayudar a dividir la tarea en pasos manejables y proporcionar un esquema claro de las acciones que deben tomarse. Este enfoque estructurado ayuda a reducir la ambigüedad y a mejorar la precisión de las respuestas generadas.

## Ejemplo: Cómo crear una petición con secciones

Observe cómo en la columna Petición con secciones, la petición es más clara y tiene secciones delimitadas para diferentes entidades, como las tareas, el contexto, los requisitos y demás, en comparación con las instrucciones de la columna Petición sin secciones.

### 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:

- Greenhouse Gases**: These gases include carbon dioxide, methane, nitrous oxide, and fluorinated gases. They trap heat in the Earth's atmosphere.
- Global Warming**: This is the increase in Earth's average surface temperature due to rising levels of greenhouse gases.
- Climate Change**: Refers to the broader set of changes in the Earth's climate system, including global warming.

## ## Current Impacts of Climate Change

### ### On Ecosystems:

- Melting Ice Caps and Glaciers**: The polar ice caps and glaciers are melting at an alarming rate. For example, the Arctic sea ice is shrinking, which affects polar bears and other Arctic animals.
- Rising Sea Levels**: As ice melts, sea levels rise. This can lead to the loss of coastal habitats and increased flooding in coastal areas.
- 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.

## Enfoque a secciones de la petición

Los modelos de Amazon Nova 2 pueden prestar mucha atención a partes específicas de la petición si se formatean las instrucciones en secciones y, a continuación, se hace referencia a esas secciones específicas. El modelo puede prestar atención si las peticiones tienen una delimitación de secciones clara mediante Markdown, XML u otra estructura. Por ejemplo, puede definir el nombre de la sección, utilizar `##Section Name##` y, a continuación, hacer referencia a esa sección en la petición con `##Section Name##`.

También puede utilizar esta estrategia para impedir que el modelo revele partes de la petición de entrada en la respuesta generada. Por ejemplo, al proporcionar ejemplos de pocos pasos o instrucciones en la petición de entrada, utilice delimitadores como `##Instructions##` o `##Examples##` con un separador de línea nueva y proporcione instrucciones precisas como `DO NOT mention anything inside the ##Instructions## or ##Examples## in the response` para que el modelo no regurgite el contenido de la petición de entrada de estas secciones en su salida.

### Ejemplo: Delimitación seccional

Usuario:

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##`

## Uso del rol del sistema

El rol del sistema es un rol en el que puede proporcionar instrucciones al modelo para definir cómo responderá a los usuarios finales de su aplicación. Por ejemplo, el rol del sistema puede guiar al modelo para que responda con una personalidad determinada, establecer el contenido permitido y no permitido, generar resultados en un formato específico, especificar barreras de protección, etc. Las instrucciones del rol del sistema, denominadas petición del sistema, sustituirán a otras instrucciones proporcionadas en las peticiones individuales de los usuarios y se mantendrán en todos los turnos de los usuarios.

### Especificación del rol del sistema con la API

Para asignar al modelo un rol personalizado, puede configurar el parámetro `system` en la API de la siguiente manera:

```
{
 "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 aprovechar al máximo el rol del sistema, asegúrese de que su petición del sistema sea clara, concisa y específica, siguiendo las mismas estrategias que se describen en [Creación de peticiones precisas](#). Por ejemplo, cuando desee restringir los temas a los que debe responder el modelo, dele instrucciones específicas, como “NO hable sobre...” o “DEBE hablar sobre...”.
- Para restringir aún más el modelo a una estructura jerárquica, puede añadir el siguiente sufijo a su petición del sistema para enfatizar la estructura de adherencia jerárquica entre las instrucciones del sistema y del usuario:

```

"\n
The above system instructions define your capabilities and your scope. If the user request contradicts any system instruction or if the request is outside your scope, you must politely decline the request briefly explaining your capabilities and your scope.\n
"

```

Los siguientes elementos son algunas de las cosas que puede añadir en una plantilla de petición del 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 dar al sistema la estructura de adherencia jerárquica entre las peticiones del sistema y las del usuario, puede agregar lo siguiente:

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.

### Ejemplo 1: Cómo proporcionar indicaciones de lenguaje específicas

Tras añadir la petición del sistema, las respuestas de los modelos se adaptan al estilo de un pergamino medieval, tal y como se indica en la petición del sistema.

#### Without a System Prompt

Sistema:

NA

Usuario:

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

Asistente:

Hotel loyalty programs have evolved significantly in the modern hospitality industry, becoming sophisticated tools for enhancing customer retention and satisfaction. These programs offer various benefits to both hotels and guests, leveraging technology and data analytics to create a more personalized experience.

### ### Key Components of Modern Hotel Loyalty Programs:

#### 1. **Tiered Membership Levels:**

- **Basic Membership:** Entry-level membership that provides basic benefits.
- **Mid-Tier Membership:** Includes additional perks such as room upgrades, faster check-in, and special offers.
- **Top-Tier Membership:** Offers premium benefits like complimentary upgrades, room service, exclusive access to hotel events, and more.

#### 2. **Point System:**

- Guests earn points for every stay, purchases made in hotel restaurants, and other activities.
- Points can be redeemed for free nights, upgrades, or other rewards.

#### 3. **Mobile App Integration:**

- Modern programs often have a dedicated mobile app that allows guests to easily manage their account, check in, and access exclusive offers.
- Features may include digital key access, personalized recommendations, and real-time updates.

#### 4. **Personalization:**

- Utilizing data analytics, hotels can tailor recommendations and offers to individual guest preferences, enhancing the overall experience.
- Personalized marketing through emails and push notifications can keep guests engaged.

#### 5. **Cross-Brand Benefits:**

- Some loyalty programs offer benefits across multiple brands within a hotel group or even within different hospitality groups.
- This can include discounts, points transfers, and combined rewards.

#### 6. **Social Media Integration:**

- Many programs encourage social media sharing and reviews, which can enhance the hotel's online presence and attract new guests.
- Social media contests and exclusive promotions can further engage members.

#### 7. **Sustainability Initiatives:**

- Modern loyalty programs increasingly incorporate sustainability, offering points or rewards for eco-friendly choices like reducing plastic use or participating in recycling programs.

### ### Benefits to Guests:

#### 1. **Financial Savings:**

- Accumulation of points for free or discounted stays.
- Exclusive discounts and offers not available to non-members.

#### 2. **Enhanced Services:**

- Faster check-in, preferred room assignments, and personalized services.
- Access to exclusive events and experiences.

#### 3. **Convenience:**

- Easy booking and management through mobile apps.
- Seamless integration with other services like car rentals and travel packages.

#### 4. **Recognition and Prestige:**

- Status symbols like elite membership levels.
- Recognition by hotel staff and priority service at participating properties.

### ### Benefits to Hotels:

#### 1. **Increased Guest Loyalty:**

- Encourages repeat visits and long-term relationships with guests.
- Helps retain customers even when faced with competition.

#### 2. **Data Collection and Analysis:**

- Provides valuable insights into guest preferences and behaviors.
- Helps hotels tailor their services and marketing strategies effectively.

#### 3. **Revenue Growth:**

- Drives up room occupancy and average daily rate (ADR) through repeat business.
- Cross-selling opportunities within the hotel (e.g., dining, spa services).

#### 4. **Market Differentiation:**

- Helps hotels stand out in a competitive market.
- Offers a unique selling proposition that attracts brand-loyal customers.

### ### Conclusion:

Modern hotel loyalty programs have become a critical component of the hospitality industry, leveraging technology and data to create personalized, engaging, and

rewarding experiences for guests. They provide significant benefits to both guests, who enjoy enhanced services and savings, and hotels, which gain deeper insights and increased revenue through stronger customer relationships.

## With a System Prompt

Sistema:

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

Usuario:

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

Asistente:

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.

## Ejemplo 2: Cómo proporcionar barreras de protección

Con la adición de la petición del sistema, los usuarios pueden añadir barreras de protección para sus aplicaciones a fin de protegerlas de cualquier uso no previsto. A continuación se muestra un ejemplo de cómo las barreras de protección pueden hacer que el modelo se centre en la tarea deseada.

### Without a System Prompt

Sistema:

NA

Usuario:

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.)

Asistente:

**\*\*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

### Usuario:

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.)

### Asistente:

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.

## Cómo proporcionar ejemplos (petición con pocos pasos)

Al incluir algunos ejemplos de su tarea en la petición, puede crear una plantilla estructurada para que Amazon Nova 2 la siga. Esto reduce la ambigüedad y mejora la precisión y la calidad del resultado. La técnica que consiste en proporcionar ejemplos claros para que las respuestas del modelo estén más alineadas con el resultado deseado se denomina petición con pocos pasos.

El concepto de petición con pocos pasos consiste en proporcionar al modelo de lenguaje algunos ejemplos de la tarea, junto con el formato de entrada y salida, y luego pedirle que genere el resultado para una nueva entrada basada en los ejemplos proporcionados. Este método también ayuda a aclarar instrucciones o tareas complejas, lo que facilita que Amazon Nova 2 comprenda e interprete lo que se pide.

En qué ayuda añadir ejemplos a la petición:

Añadir ejemplos puede ayudar al modelo a producir lo siguiente:

- respuestas coherentes y uniformes con el estilo de los ejemplos,
- respuestas eficaces debido a que reducen la posibilidad de malinterpretar las instrucciones y minimizan las alucinaciones.

La medida en que el rendimiento del modelo mejore utilizando peticiones con pocos pasos dependerá de la calidad y la diversidad de los ejemplos que elija. Los siguientes elementos muestran las características de los buenos ejemplos en la petición:

- Seleccione ejemplos diversos: los ejemplos elegidos deben representar la distribución de sus entradas/salidas esperadas en términos de diversidad (desde casos de uso comunes hasta casos extremos) para cubrir adecuadamente los casos de uso relevantes. Es importante evitar cualquier sesgo en los ejemplos, ya que los sesgos en las entradas también pueden provocar sesgos en las salidas.
- Los niveles de complejidad deben coincidir: la complejidad de los ejemplos proporcionados debe alinearse con la tarea o el escenario objetivo. Es importante asegurarse de que el grado de complejidad esté alineado entre la entrada esperada y el ejemplo elegido en la petición.
- Garantice la relevancia: los ejemplos seleccionados deben estar directamente relacionados con el problema o el objetivo en cuestión. Esto garantiza la coherencia y la uniformidad en las respuestas.

 Tip

Si las sugerencias anteriores no funcionan, le recomendamos que cree un sistema basado en RAG que amplíe la petición con una selección dinámica de ejemplos basada en las similitudes entre la consulta introducida por el usuario y un conjunto de ejemplos disponible.

### Ejemplo 1: Cómo proporcionar ejemplos en la petición del usuario

En este caso, su usuario intenta clasificar los tickets de atención al cliente entrantes en categorías predefinidas. Puede proporcionar a los modelos de Amazon Nova 2 algunos ejemplos de tickets que estén clasificados correctamente para mejorar su comprensión de las categorías y el lenguaje utilizado en los tickets. Los ejemplos deben ser concisos y representar todas las tareas objetivo de su aplicación. Si hay un nombre de campo específico que sea significativo para las tareas, como Ticket o Category en este ejemplo, su usuario puede usar esos campos directamente seguidos de dos puntos ":".

#### 0-shot prompt

Usuario:

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."

Asistente:

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

Usuario:

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."

Asistente:

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.

## Ejemplo 2: Cómo proporcionar ejemplos como petición por turno

En este ejemplo, los ejemplos se proporcionan como turnos, uno por ejemplo, donde el rol User contiene la entrada y el rol Assistant contiene el resultado esperado para ese ejemplar.

### 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

Usuario:

I have 20\$ in my pocket.

Asistente:

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

Usuario:

I love to eat pizza.

Asistente:

Food

Usuario:

I enjoy watching movies.

Asistente:

Entertainment

Usuario:

I am going to the gym after this.

Asistente:

Health

Usuario:

I have 20\$ in my pocket.

Asistente:

Wealth

### Ejemplo 3: Cómo proporcionar ejemplos en la petición del sistema

En este ejemplo, puede especificar una sección de “Ejemplo” y, a continuación, enumerar una serie de ejemplos en la petición del sistema. Esta forma de incluir ejemplos en la petición resulta especialmente útil si los ejemplos son largos y complejos y ayuda al modelo a localizarlos.

#### 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.

Usuario:

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



## Asistente:

### # Project Update Report

#### ## Executive Summary

This report provides a comprehensive update on the project milestones achieved, tasks completed, and future plans. Our team has made significant progress, and we are on track to meet the project goals. The following sections outline the details of our accomplishments and upcoming activities.

---

#### ## Project Milestones Achieved

##### ### \*\*1. Project Initiation\*\*

- \*\*Milestone Date:\*\* July 15, 2023
- \*\*Description:\*\* Completed initial project planning and secured stakeholder approval.

##### ### \*\*2. System Design Completion\*\*

- \*\*Milestone Date:\*\* September 30, 2023
- \*\*Description:\*\* Finished the detailed system design and received positive feedback from technical review meetings.

##### ### \*\*3. Prototype Development\*\*

- \*\*Milestone Date:\*\* November 15, 2023
- \*\*Description:\*\* Developed and tested a working prototype of the system.

---

#### ## Tasks Completed

##### ### \*\*1. Requirement Gathering\*\*

- \*\*Description:\*\* Conducted comprehensive stakeholder interviews and collected detailed requirements.
- \*\*Highlighted Important Tasks:\*\*
  - \*\*User Story Mapping:\*\* Mapped out user stories to ensure all user needs are addressed.
  - \*\*Requirement Documentation:\*\* Created detailed requirement specifications.

##### ### \*\*2. System Architecture Design\*\*

- \*\*Description:\*\* Designed the system architecture, focusing on scalability and maintainability.
- \*\*Highlighted Important Tasks:\*\*

- **Technology Stack Selection:** Chose the appropriate technology stack based on project requirements.
- **Architecture Diagrams:** Developed detailed architecture diagrams for easy understanding.

### **3. Prototype Development and Testing**

- **Description:** Developed and rigorously tested the prototype.
- **Highlighted Important Tasks:**
  - **Coding:** Implemented core functionalities of the prototype.
  - **Testing:** Conducted unit and integration testing to ensure prototype reliability.

---

## **Future Plans**

### **1. Full System Development**

- **Description:** Begin the full-scale development of the system based on the approved design and prototype.
- **Highlighted Important Tasks:**
  - **Module Development:** Develop each module as per the design specifications.
  - **Code Reviews:** Implement regular code reviews to maintain code quality.

### **2. User Acceptance Testing (UAT)**

- **Description:** Conduct UAT to ensure the system meets user requirements and is ready for deployment.
- **Highlighted Important Tasks:**
  - **Test Plan Development:** Create detailed UAT plans and test cases.
  - **UAT Execution:** Execute UAT and gather feedback for final adjustments.

### **3. Deployment and Training**

- **Description:** Deploy the system and provide necessary training to end-users.
- **Highlighted Important Tasks:**
  - **Deployment:** Roll out the system to the production environment.
  - **Training Sessions:** Organize training sessions for users to familiarize them with the new system.

---

## **Conclusion**

Our project has successfully achieved key milestones and completed significant tasks. With the current momentum, we are well-positioned to meet our future objectives. We remain committed to delivering a high-quality system that meets all stakeholder expectations.

---

**\*\*Prepared by:\*\***

[Your Name]

[Your Position]

[Date]

**\*\*Contact Information:\*\***

[Your Email]

[Your Phone Number]

---

This detailed update aims to keep stakeholders informed and reassured about the project's progress and future direction. For any queries or further information, please do not hesitate to contact me directly.

## 2-shot Prompt

Sistema:

You are an AI assistant helping to draft professional reports for enterprise stakeholders. Below are a few examples of well-formatted project update reports to guide your response.

<Example 1>

<b>Project Update Report</b><br>

<i>Date:</i> January 15, 2023<br>

<hr>

<b>Project Milestones Achieved:</b><br>

- Successfully launched the new CRM system.<br>
- Integrated the marketing automation tool.<br>
- Completed the employee training sessions.

<b>Tasks Completed:</b><br>

- Developed the user manual.<br>
- Conducted system testing.<br>
- Prepared the training materials.

<b>Future Plans:</b><br>

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

<hr>

<b>Prepared by:</b><br>

[Your Name]<br>

[Your Position]<br>

[Your Contact Information]

<Example 2>

<b>Project Update Report</b><br>

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

<hr>

<b>Project Milestones Achieved:</b><br>

- Launched the new website.<br>
- Completed the SEO optimization.<br>
- Organized the stakeholder meeting.

<b>Tasks Completed:</b><br>

- Designed the website layout.<br>
- Wrote the content for the website.<br>
- Tested the website functionality

<b>Future Plans:</b><br>

- Implement the analytics tracking.<br>
- Launch the social media campaign.<br>
- Gather feedback from stakeholders.

<hr>

<b>Prepared by:</b><br>

[Your Name]<br>

[Your Position]<br>

[Your Contact Information]

Usuario:

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

Asistente:

**Project Update Report**  
*Date:* October 5, 2023  

---

**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 llamadas a herramientas

La llamada a herramientas está disponible para los modelos de Amazon Nova si se incluye un esquema de configuración de herramientas en su solicitud. La petición del modelo se ampliará con esta configuración de herramientas, por lo que es un punto de partida muy importante para empezar a optimizar su sistema de llamadas a herramientas.

Considere estos principios clave:

- Las definiciones de las herramientas deben ser claras y concisas. Deben ser fáciles de entender, y la intención debe ser muy evidente.
- Utilice los diferenciadores clave y las condiciones límite para definir cuándo se debe utilizar una herramienta en lugar de otra.
- Sea crítico con los tipos de argumentos de entrada. Pregúntese: ¿tienen sentido y se esperaría que se usaran de esa manera normalmente?

### Uso de “Elección de herramientas” para controlar cuándo se llama a una herramienta

El parámetro de elección de herramientas le permite personalizar el comportamiento de las llamadas a herramientas con el modelo. Le recomendamos que lo utilice para controlar con precisión qué herramientas se invocan y cuándo.

Por ejemplo, para casos de uso como la salida estructurada, es posible que desee llamar a una herramienta específica cada vez que se invoque Amazon Nova. Puede definir el esquema de la salida como herramienta y, a continuación, establecer la elección de herramienta con el nombre de esa herramienta.

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

Para muchos casos de uso de agentes, es posible que desee asegurarse de que el modelo siempre seleccione una de las herramientas disponibles. Para ello, puede establecer la elección de herramienta en `any`, que llamará exactamente a una herramienta cada vez que se invoque el modelo.

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

Por último, para los casos de uso en los que la decisión de llamar a una herramienta depende en gran medida del contexto de la conversación, puede establecer la elección de herramienta como auto. Este es el comportamiento predeterminado y dejará la selección de la herramienta completamente a cargo del modelo.

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

## Técnicas de peticiones avanzadas

En estas secciones, se proporciona una guía avanzada sobre cómo mejorar la calidad de las peticiones y aprovechar características clave, como el pensamiento extendido.

### Uso del modo de razonamiento

Los modelos de Amazon Nova 2 ofrecen un modo de razonamiento opcional que mejora el enfoque del modelo para la resolución de problemas complejos al permitirle resolverlos de forma sistemática antes de responder. Aprovechar el modo de razonamiento del modelo es una forma eficaz de mejorar la precisión de las peticiones.

Cuándo se debe usar: se recomienda el modo de razonamiento para tareas complejas, como casos de uso con:

- Múltiples pasos de razonamiento: demostraciones matemáticas, diseño de algoritmos, arquitectura de sistemas
- Información de referencia cruzada: análisis de documentos, comparación de opciones, evaluación de compensaciones
- Cálculos propensos a errores: modelos financieros, análisis de datos, depuración compleja
- Planificación con restricciones: optimización de recursos, administración de dependencias, evaluación de riesgos

- Clasificaciones complejas: categorización con varias etiquetas, taxonomías jerárquicas, límites de decisión matizados
- Escenarios de llamada a herramientas: flujos de trabajo de API de varios pasos, optimización de consultas de bases de datos, integraciones coordinadas de sistemas

 Note

Para obtener más información sobre el modo de razonamiento, consulte [Uso del razonamiento](#).

### Adopción de un enfoque descendente

En el caso de situaciones en las que el modelo tenga que evaluar varios enfoques para resolver el problema, pídale que adopte un enfoque descendente.

- Los modelos de Amazon Nova 2 funcionan mejor cuando el modelo comienza con un panorama general y luego lo divide en subproblemas o pasos más pequeños y detallados.
- Indique explícitamente al modelo que identifique primero el objetivo principal y, a continuación, lo descomponga en componentes manejables antes de analizar los detalles de cada parte.
- Este enfoque estructurado ayuda al modelo a organizar su pensamiento y producir cadenas de razonamiento más coherentes.

### Ejemplo:

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

### Dirección de la cadena de pensamiento

Si bien el modo de razonamiento proporciona una mayor precisión mediante la resolución sistemática de problemas, hay situaciones específicas en las que las peticiones de la cadena de pensamiento (CoT) en el modo sin razonamiento pueden satisfacer mejor sus necesidades.

### Cuándo se debe usar:



- **Transparencia y auditabilidad:** cuando desee ver, verificar o auditar el proceso de razonamiento del modelo, la CoT ofrece una visibilidad total de cada paso. Es fundamental para sectores regulados, decisiones de alto riesgo o cuando se quiere documentar la lógica detrás de una respuesta.
- **Estructuras de razonamiento personalizadas:** utilice la CoT para aplicar metodologías o patrones de razonamiento específicos. Puede guiar al modelo para que siga los marcos de decisión de su organización, utilice enfoques de resolución de problemas específicos para un dominio o se garantice que los factores se tengan en cuenta en un orden específico.
- **Desarrollo y depuración de peticiones:** durante la fase de ingeniería de peticiones, la CoT le permite entender cómo el modelo aborda los problemas, identifica dónde falla el razonamiento e itera las peticiones de forma más eficaz.
- **Enfoques híbridos:** considere la posibilidad de utilizar la CoT durante el desarrollo para perfeccionar las peticiones y, a continuación, cambiar al modo de razonamiento para la implementación en producción una vez que confíe en el enfoque del modelo para su caso de uso específico.

#### Note

No todas las tareas requieren la CoT. Para tareas más sencillas, permita que el modelo utilice su propio proceso de razonamiento.

Orientación de la dirección de la CoT del modelo:

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

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

Utilización de ventanas de contexto largas

Los modelos de Amazon Nova 2 tienen una longitud de contexto admitida de 1 millón de tokens y destacan en la comprensión del código y la respuesta a preguntas en documentos largos. Su rendimiento (lo que incluye el cumplimiento de peticiones y el uso de herramientas) puede disminuir ligeramente a medida que aumenta el tamaño del contexto.

Modo de uso:

- Ponga los datos de formato largo al principio: coloque los documentos largos y las entradas cerca del comienzo de la petición. Colóquelos antes de la consulta, las instrucciones y los ejemplos.
- Ponga las instrucciones al final: coloque las instrucciones al final de la petición. El modelo funciona mejor cuando se proporciona primero el contexto y las instrucciones se indican al final.
- Estructure los marcadores de inicio y final del contenido del documento: utilice marcadores de inicio y final, como `DOCUMENT {idx} START` y `DOCUMENT {idx} END`, para indicar el inicio y el final de documentos largos, en los que {idx} representa el índice del documento específico.

Plantilla de de ejemplo de:

```
// 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
```

Texto de apoyo como base de las respuestas

Le recomendamos que le proporcione al modelo información fiable relevante para la consulta de entrada. Esta información, junto con la consulta de entrada, a menudo forma parte del sistema denominado generación aumentada por recuperación (RAG).

- En este proceso, se agrega algún documento o información contextual pertinente a la propia petición del usuario para que el modelo obtenga contenido fiable y genere una respuesta pertinente y precisa.
- Indicar a Amazon Nova 2 que responda con un texto de referencia de un origen fiable puede guiarlo para redactar su respuesta en función del material proporcionado y garantizar que se

base en información precisa y pertinente, lo que mejora la fiabilidad y la credibilidad del contenido generado.

- Utilizar un texto de referencia puede ayudar a evitar las alucinaciones, lo que mejora la calidad general y la fiabilidad de las respuestas. Para minimizar las alucinaciones, le recomendamos que mencione **DO NOT USE INFORMATION THAT IS NOT IN REFERENCE TEXTS!** de forma explícita en las instrucciones del modelo.

## Plantilla de petición

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}

Ejemplo: proporcionar un contexto de base ayuda a evitar que el modelo alucine

En este ejemplo, se muestra cómo se puede evitar que el modelo alucine al basar el contexto.

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!

Usuario:

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.

## Uso de marcadores de citas como base

Para tareas con documentos largos, le recomendamos que indique al modelo de Amazon Nova 2 que fundamente sus respuestas con citas de las secciones pertinentes de los documentos antes de continuar con la tarea.

Este enfoque ayuda al modelo a centrarse en la información más pertinente y a evitar que se distraiga con contenido superfluo. Cuando solicite que el modelo fundamente su respuesta, las secciones que se pueden citar deben estar numeradas. Por ejemplo, Passage %[1]%, Passage %[2]%, etc.

Ejemplos: uso de marcadores de citas

## Example Petición con marcadores de citas

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)

...

Después de extraer la información clave en función de la tarea del usuario, puede utilizar las métricas financieras extraídas para responder a las preguntas pertinentes, como se muestra a continuación:

### Example Análisis de seguimiento con 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

## Uso del Anclaje web de Nova

En lugar de pedir directamente citas para que el modelo se base en el texto de apoyo, los modelos de Amazon Nova 2 proporcionan una herramienta de anclaje web interna que se puede utilizar. Al habilitar la opción, los modelos de Amazon Nova 2 consultarán directamente la web y los gráficos de conocimiento de Amazon y basarán la respuesta final con citas.

Para obtener más información sobre cómo aprovechar el Anclaje web de Amazon Nova, puede consultar la [guía del usuario del Anclaje web de Amazon Nova](#).

## Producción de una salida estructurada

Para garantizar formatos de salida coherentes y estructurados, puede utilizar salidas estructuradas, lo que incluye formatos como XML, JSON, Markdown o el uso de la funcionalidad de uso de la herramienta.

- Este enfoque permite que los casos sistemas descendentes comprendan y analicen de manera más eficaz las salidas generadas por el modelo.
- Al proporcionar instrucciones explícitas al modelo, las respuestas se generan de una manera que se ajusta a un esquema predefinido.

Por ejemplo, si el analizador descendente espera convenciones de nomenclatura específicas para las claves de un objeto JSON, debe especificar el esquema de la respuesta al final de la petición. Además, si prefiere que las respuestas estén en formato JSON sin ningún texto de preámbulo, indíquese al modelo. Es decir, indique explícitamente: Genere solo la salida JSON. NO elabore ningún preámbulo. para garantizar una salida limpia.

### Tip

- Observamos que la mejor forma de cumplir con los requisitos de formato de los datos es cuando se definen en el propio esquema en lugar de mediante el uso de ejemplares (por ejemplo, si se especifican las fechas en formato AAAA/MM/DD).
- Para obtener salidas JSON sencillas con un máximo de 10 claves, puede encontrar el esquema a continuación. Para esquemas más complejos, le recomendamos que defina su esquema mediante una herramienta. El uso de la herramienta aprovecha una técnica llamada decodificación restringida que aumentará la adherencia del modelo a estos esquemas complejos.

## Esquemas de formato común

A continuación se muestran ejemplos de esquemas de formato común.

### 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 )

"""
```

Relleno previo del contenido del asistente

Si está produciendo una salida estructurada en un modo sin razonamiento, puede desplazar la respuesta del modelo si rellena previamente el contenido del asistente.

El relleno previo mejora la coherencia del formato de salida en el modo sin razonamiento. Le permite dirigir las acciones del modelo, omitir los preámbulos y aplicar formatos de salida específicos, como JSON y XML. Por ejemplo, si rellena previamente el contenido del asistente con { o ```json, esa entrada guía al modelo para generar el objeto JSON sin información adicional.

Tip

Si lo que busca es extraer JSON de forma explícita, un patrón habitual consiste en rellenarlo previamente con ```json y agregar una secuencia de detención en ```. Esto garantiza que el modelo genere un objeto JSON que se pueda analizar mediante programación.

Example Relleno previo del contenido del asistente

En los siguientes ejemplos de código, se muestra cómo prellenar con la 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())
```

Especificación de una herramienta para usarla en esquemas complejos

Otro enfoque consiste en utilizar herramientas para forzar un esquema específico para la respuesta del modelo mediante la inclusión del esquema JSON de Pydantic en la sección de esquema de uso de herramientas. Puede especificar la elección de herramienta según el esquema proporcionado y la respuesta de Amazon Nova se estructurará en función de la herramienta seleccionada. Para obtener más información sobre cómo aprovechar el uso de herramientas, consulte [Uso de herramientas](#).

Ejemplos

Ejemplo 1: Cómo añadir un esquema de salida

Al añadir la sección del esquema de salida con el esquema apropiado, el modelo prefiere ajustarse a ese esquema. Sin embargo, la salida del modelo no es determinista y puede diferir del esquema de salida.

Unspecific Prompt

Usuario:

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.

Asistente:

```
```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

### Usuario:

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"
}]
```

### Asistente:

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

## Ejemplo 2: Cómo prellenar la respuesta del modelo

Otro enfoque consiste en prellenar la respuesta del modelo incluyendo el texto inicial deseado en el mensaje del asistente. En este caso, la respuesta del modelo de Amazon Nova continuará desde donde termina el mensaje del asistente.

Consejo: el relleno previo solo es válido cuando el razonamiento no está activado.

Usuario:

```
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.

Asistente (relleno previo):

```
```json
```

Asistente:

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

Ejemplo 3: Cómo especificar una herramienta para usar

Como alternativa al uso de la técnica de relleno previo para obtener una salida estructurada, puede combinar la funcionalidad de las herramientas de Nova con toolChoice. En este ejemplo, el modelo generará una llamada a la herramienta que se adhiera al esquema JSON proporcionado y que llame a la herramienta específica indicada en el formato JSON completo definido. Para obtener orientación adicional, consulte [Sistemas avanzados](#).

Usuario:

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 multilingües

Los modelos de Amazon Nova 2 se han entrenado en más de 200 idiomas y se han optimizado para 15 idiomas.

Temas

- [Peticiones de traducción precisas](#)
- [Aplicación de convenciones de redacción coherentes](#)

Peticiones de traducción precisas

Para aprovechar esta capacidad para traducciones de formato corto (unas pocas frases), puede pedir al modelo que traduzca el texto al idioma de destino especificado.

Example Peticiones de traducción

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}

Aplicación de convenciones de redacción coherentes

En los lenguajes basados en caracteres, los modelos de Amazon Nova 2 pueden utilizar el conjunto de caracteres del idioma de origen. Puede utilizar la siguiente petición para aplicar una salida coherente.

Example Aplicación de convenciones de redacción

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

Llamada a herramientas

Sistemas agénticos

Temas

- [Establecimiento de los parámetros de inferencia correctos](#)
- [Consideración de los requisitos de latencia](#)
- [Uso de un lenguaje intencionado para las instrucciones de llamada a herramientas](#)
- [Aprovechamiento de los comandos de “pensamiento”](#)
- [Orden de las llamadas a herramientas](#)
- [Creación de esquemas de herramientas de calidad](#)
- [Creación de subagentes](#)
- [Uso de herramientas para entradas multimodales](#)
- [Siguiendo pasos](#)

Establecimiento de los parámetros de inferencia correctos

La llamada a herramientas requiere una salida estructurada muy específica del modelo y se mejora mediante el uso de los siguientes parámetros de inferencia:

- Modo sin razonamiento. Temperatura: 0,7 y Top P: 0,9
- Modo de razonamiento. Temperatura: 1 y Top P: 0,9

Consideración de los requisitos de latencia

Tip

Los modelos de Amazon Nova 2 pueden llamar a herramientas con el razonamiento activado y desactivado. Sin embargo, los modos de razonamiento tienen un impacto significativo en la latencia.

En el caso de aplicaciones sensibles a la latencia, se debe optimizar el modo de razonamiento desactivado y, en la medida de lo posible, simplificar las llamadas a herramientas necesarias. Divida los flujos de trabajo de varios pasos en pasos discretos para reducir la dependencia del modelo de regurgitar parámetros innecesarios.

Uso de un lenguaje intencionado para las instrucciones de llamada a herramientas

Nombres de herramientas: hacer referencia a las herramientas en la petición del sistema es habitual en los sistemas de llamadas a herramientas para indicar al modelo cuándo llamar a una herramienta. Cuando haga referencia a herramientas en la petición, le recomendamos que utilice el nombre de la herramienta en lugar de referencias o ejemplos en formato xml o Python.

Ejemplo de una buena referencia a una herramienta

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

Ejemplo de una mala referencia a una herramienta

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

Aprovechamiento de los comandos de “pensamiento”

Para todos los casos de uso en los que pensar sea beneficioso para la llamada a herramientas, te recomendamos que aproveche el modo de razonamiento en lugar de hacer peticiones al modelo para que “piense en etiquetas” o que utilice una herramienta de “pensamiento”.

Los modelos de Amazon Nova 2 están entrenados ampliamente para el modo de razonamiento y producirán los resultados óptimos cuando se utilicen en el modo de razonamiento para la cadena de pensamiento.

Orden de las llamadas a herramientas

En los casos de uso que puedan requerir el uso simultáneo de llamadas a herramientas integradas y nativas, el modelo se inclina por llamar primero a las herramientas integradas.

No indique al modelo que actúe de forma diferente en la petición. En su lugar, téngalo en cuenta al diseñar el flujo de trabajo.

Por ejemplo, si no desea que el modelo utilice herramientas integradas, no las incluya en el flujo de trabajo para que el modelo no se incline por ellas.

Creación de esquemas de herramientas de calidad

Los esquemas de herramientas son uno de los lugares clave en los que puede usar la ingeniería de peticiones para sistemas de llamada a herramientas de forma eficaz. Sin embargo, es importante tener en cuenta lo que se captura en el propio esquema de la herramienta, cómo se describe

semánticamente cada elemento del esquema y cómo la petición del sistema hace referencia a las herramientas y los elementos del esquema en las instrucciones del sistema.

Los modelos de Amazon Nova 2 están optimizados para ofrecer descripciones concisas en los esquemas de la herramienta. Sea breve.

Directrices de esquema de la herramienta frente a petición del sistema:

Incluya lo siguiente en el esquema de la herramienta:

- Funcionalidad básica: qué hace la herramienta (se recomiendan entre 20 y 50 palabras)
- Especificaciones de los parámetros: descripciones claras de cada parámetro (alrededor de 10 palabras por parámetro)
- Formatos esperados: tipos de datos (como enum, int, float), campos obligatorios y rangos de valores válidos

Incluya lo siguiente en la petición del sistema:

- Dedique una sección `#Tool Usage` a la lógica de orquestación (cuándo y por qué se deben utilizar herramientas específicas) y a las reglas empresariales (lógica condicional, requisitos de secuenciación y dependencias).
- Estrategias de gestión de errores: agregue una sección `#Error Handling and Troubleshooting` con instrucciones sobre cómo responder a fallos o a salidas inesperadas
- Formato de salida: agregue detalles sobre cómo se presenta al usuario

Ejemplo

```
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>
```

Creación de subagentes

Considere la posibilidad de crear subagentes especializados en lugar de un solo agente con muchas herramientas cuando se encuentre con lo siguiente:

- El número de herramientas supera las 20: los conjuntos de herramientas grandes se vuelven difíciles de administrar y aumentan los errores de selección
- Dominios funcionales distintos: las herramientas se agrupan de forma natural en categorías separadas (por ejemplo, la recuperación de datos, el procesamiento o la elaboración de informes)
- Esquemas complejos: cuando la profundidad de los parámetros supera los 3 o 4 niveles o las herramientas tienen interdependencias complejas
- Duración de la conversación: los flujos de trabajo que suelen superar los 15 o 20 turnos pueden beneficiarse de la ayuda de subagentes especializados
- Degradación del rendimiento: si observa una disminución de la precisión en la selección de herramientas o un aumento de la latencia

 Tip

Los servidores MCP vienen con herramientas y esquemas que no puede controlar. Incluya solo las herramientas necesarias para que su flujo de trabajo complete la tarea requerida.

Uso de herramientas para entradas multimodales

En el caso de las tareas multimodales, no hemos observado ninguna mejora en la precisión al aprovechar las herramientas para tareas estructuradas (como la extracción o la generación de marcas de tiempo).

En su lugar, le recomendamos que consulte las secciones pertinentes de la sección [Petición de entradas multimodales](#) para obtener información sobre cómo activar correctamente el modelo con las plantillas proporcionadas.

Siguientes pasos

- Para las peticiones multimodales, consulte [Petición de entradas multimodales](#).

Peticiones de entradas multimodales

En las siguientes secciones, se proporciona orientación para la comprensión de imágenes y videos. Para peticiones relacionadas con audio, consulte la sección [the section called “Petición de conversación de voz”](#).

Directrices multimodales generales

Peticiones del usuario y del sistema

Para los casos de uso de comprensión multimodal, cada solicitud debe incluir el texto de la petición del usuario. Las peticiones del sistema, que solo pueden contener texto, son opcionales.

Las peticiones del sistema se pueden usar para especificar una persona para el modelo y para definir la personalidad general y el estilo de la respuesta, pero no deben usarse para definir tareas detalladas ni para dar instrucciones del formato de salida.

Incluya la definición de la tarea, las instrucciones y los detalles del formato en la petición del usuario para que tenga un efecto más fuerte que la petición del sistema en los casos de uso multimodales.

Orden del contenido

Una solicitud de comprensión multimodal enviada a Amazon Nova debe contener uno o más archivos y una petición del usuario. La petición de texto del usuario debe ser el último elemento del mensaje, siempre después del contenido de la imagen, el documento o el video.

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

En los casos en los que desee hacer referencia a archivos específicos desde la petición del usuario, utilice elementos de “texto” para definir las etiquetas que preceden a cada bloque de archivos.

```
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>" }
  ]
}
```

Comprensión de documentos e imágenes

En las siguientes secciones, se proporciona orientación sobre cómo crear peticiones para tareas que requieren comprender o analizar imágenes y documentos.

Extracción de texto a partir de imágenes

Los modelos de Amazon Nova pueden extraer texto de las imágenes, una capacidad denominada reconocimiento óptico de caracteres (OCR). Para obtener los mejores resultados, asegúrese de que

la entrada de imagen que proporcione al modelo tenga una resolución lo suficientemente alta como para que los caracteres del texto sean fáciles de distinguir.

Para casos de uso de extracción de texto, recomendamos la siguiente configuración de inferencia:

- Temperatura: predeterminada (0,7)
- TopP: predeterminado (0,9)
- No habilite el razonamiento

Los modelos de Amazon Nova pueden extraer texto en formato Markdown, HTML o LaTeX. Se recomienda la siguiente plantilla de petición del usuario:

```
## Instructions
Extract all information from this page using only {text_formatting} formatting. Retain
the original layout and structure including lists, tables, charts and math formulae.

## Rules
1. For math formulae, always use LaTeX syntax.
2. Describe images using only text.
3. NEVER use HTML image tags `` in the output.
4. NEVER use Markdown image tags `![]()` in the output.
5. Always wrap the entire output in ``` tags.
```

La salida está envuelta en vallas de código Markdown totales o parciales (```). Puede eliminar las vallas de código mediante código similar al siguiente:

```
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()
```

Extracción de información estructurada a partir de imágenes o texto

Los modelos de Amazon Nova pueden extraer información de imágenes en formato JSON analizable automáticamente, un proceso denominado extracción de información clave (KIE). Para realizar la KIE, proporcione lo siguiente:

- Un esquema JSON. Una definición de esquema formal que siga la especificación del esquema JSON.
- Una o más de las siguientes opciones: un archivo de documento o imagen o texto de documento

El documento o la imagen siempre deben colocarse antes de que la petición del usuario en la solicitud.

Para casos de uso de KIE, recomendamos la siguiente configuración de inferencia:

- Temperatura: 0
- Razonamiento: no es obligatorio, pero puede mejorar los resultados cuando se utilizan entradas de solo imágenes o esquemas complejos.

Plantillas de peticiones

Entrada de documentos o solo imágenes

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 de solo 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 documentos o imágenes y 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}
```

Detección de objetos y sus posiciones en imágenes

Los modelos de Amazon Nova 2 permiten identificar objetos y sus posiciones dentro de las imágenes, una tarea que a veces se denomina localización de imágenes o localización de objetos. Las aplicaciones prácticas incluyen el análisis y el etiquetado de imágenes, la automatización de la interfaz de usuario y la edición de imágenes, entre otras.

Independientemente de la resolución de entrada de la imagen y de la relación de aspecto, el modelo utiliza un espacio de coordenadas que divide la imagen en 1000 unidades horizontalmente y 1000 unidades verticalmente, con la ubicación x:0 y:0 en la parte superior izquierda de la imagen.

Los cuadros delimitadores se describen con el formato [x1, y1, x2, y2] que representa la izquierda, la parte superior, la derecha y la parte inferior, respectivamente. Las coordenadas bidimensionales se representan con el formato [x, y].

Para casos de uso de detección de objetos, recomendamos que se utilicen los siguientes valores de parámetros de inferencia:

- Temperatura: 0

- No habilite el razonamiento

Plantillas de peticiones: detección de objetos general

Se recomienda las siguientes plantilla de peticiones del usuario.

Detección de varias instancias con cuadros delimitadores:

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.

Detección de una sola región con un cuadro delimitador:

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.

Detección de varias instancias con puntos centrales:

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.

Detección de una sola región con un punto 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.

Análisis de la salida del modelo:

Cada una de las peticiones recomendadas anteriormente generará una cadena separada por comas que contiene una o más descripciones de cuadros delimitadores en un formato similar al siguiente. Puede haber una ligera variación en función de si se incluye un “.” al final de la cadena. Por ejemplo: ., [356, 770, 393, 872], [626, 770, 659, 878].

Puede analizar la información de coordenadas generada por el modelo mediante una expresión regular, como se muestra en el siguiente ejemplo de código de Python.

Ejemplo 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)
    ]
```

Ejemplo de código

Para reasignar las coordenadas normalizadas de un cuadro delimitador al espacio de coordenadas de la imagen de entrada, puede utilizar una función similar a la del siguiente ejemplo de Python.

```
def remap_bbox_to_image(bounding_box, image_width, image_height):
    return [
        bounding_box[0] * image_width / 1000,
        bounding_box[1] * image_height / 1000,
        bounding_box[2] * image_width / 1000,
        bounding_box[3] * image_height / 1000,
    ]
```

Plantillas de peticiones: detección de varias clases de objetos con posiciones

Si desea identificar varias clases de elementos en una imagen, puede incluir una lista de clases en la petición mediante uno de los siguientes enfoques de formato.

En el caso de las clases más comunes que probablemente el modelo comprenda bien, enumere los nombres de las clases (sin comillas) entre corchetes:

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

En el caso de las clases con matices, poco frecuentes o que provengan de dominios especializados con los que el modelo tal vez no esté familiarizado, incluya una definición para cada clase entre paréntesis. Como se trata de una tarea difícil, cabe esperar que el rendimiento del modelo se deteriore.

```
[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)]
```

Utilice una de las siguientes plantillas de peticiones del usuario en función del formato de salida JSON que prefiera.

Opción de petición 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]
  },
  ...
]
```

Opción de petición 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]
    },
    ...
]

```

Opción de petición 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], ...],
    ...
}

```

Opción de petición 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], ...]
    },
    ...
]

```

Análisis de la salida del modelo

La salida se codificará como un JSON que se puede analizar con cualquier biblioteca de análisis de JSON.

Plantillas de peticiones: detección de límites de interfaz de usuario de capturas de pantalla

Se recomienda las siguientes plantilla de peticiones del usuario.

Detección de la posición de elementos de interfaz de usuario en función de un objetivo:

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.

Detección de la posición de elementos de interfaz de usuario en función de 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.

Análisis de la salida del modelo:

Para cada una de las peticiones de detección de límites de interfaz de usuario anteriores, puede analizar la información de coordenadas generada por el modelo mediante una expresión regular, como se muestra en el siguiente ejemplo de código de Python.

Ejemplo 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)
    ]
```

Comprensión de videos

En las siguientes secciones, se proporciona orientación sobre cómo crear peticiones para tareas que requieren comprender o analizar videos.

Resumen de videos

Los modelos de Amazon Nova pueden generar resúmenes del contenido de videos.

Para casos de uso de resúmenes de videos, recomendamos que se utilicen los siguientes valores de parámetros de inferencia:

- Temperatura: 0
- Es posible que algunos casos de uso se beneficien de la activación del razonamiento del modelo

No se requiere ninguna plantilla de petición específica. La petición del usuario debe especificar claramente los aspectos del video que le interesan. Estos son algunos ejemplos de peticiones eficaces:

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?

Generación de subtítulos detallados para videos

Los modelos de Amazon Nova pueden generar subtítulos detallados para videos, una tarea que se denomina subtitulación densa.

Para casos de uso de subtitulación de videos, recomendamos que se utilicen los siguientes valores de parámetros de inferencia:

- Temperatura: 0
- Es posible que algunos casos de uso se beneficien de la activación del razonamiento del modelo

No se requiere ninguna plantilla de petición específica. La petición del usuario debe especificar claramente los aspectos del video que le interesan. Estos son algunos ejemplos de peticiones eficaces:

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.

Análisis de grabaciones de videos de seguridad

Los modelos de Amazon Nova pueden detectar eventos en grabaciones de seguridad.

Para casos de uso de grabaciones de seguridad, recomendamos que se utilicen los siguientes valores de parámetros de inferencia:

- Temperatura: 0
- Es posible que algunos casos de uso se beneficien de la activación del razonamiento del 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.

Extracción de eventos de videos con marcas de tiempo

Los modelos de Amazon Nova pueden identificar las marcas de tiempo relacionadas con los eventos de un video. Puede solicitar que las marcas de tiempo se formateen en segundos o como MM:SS. Por ejemplo, un evento que ocurre en la marca de tiempo 1 minuto y 25 segundos del video se puede representar como 85 o 01:25.

Para este caso de uso, recomendamos que se utilicen los siguientes valores de parámetros de inferencia:

- Temperatura: 0
- No utilice el razonamiento

Le recomendamos que utilice peticiones similares a la siguiente:

Identificación de la hora de inicio y finalización de un evento

Please localize the moment that the event "{event_description}" happens in the video. Answer with the starting and ending time of the event in seconds, such as `[[72, 82]]`. If the event happen multiple times, list all of them, such as `[[40, 50], [72, 82]]`.

Locate the segment where "{event_description}" happens. Specify the start and end times of the event in MM:SS.

Answer the starting and end time of the event "{event_description}". Provide answers in MM:SS

When does "{event_description}" in the video? Specify the start and end timestamps, e.g. `[[9, 14]]`

Identificación de varias ocurrencias de un evento

Please localize the moment that the event "{event_description}" happens in the video. Answer with the starting and ending time of the event in seconds. e.g. `[[72, 82]]`. If the event happen multiple times, list all of them. e.g. `[[40, 50], [72, 82]]`

Generación de un registro de segmentos de video con marcas de tiempo

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.

Clasificación de videos

Puede usar los modelos de Amazon Nova para clasificar videos en función de una lista predefinida de clases que proporcione.

Para este caso de uso, recomendamos que se utilicen los siguientes valores de parámetros de inferencia:

- Temperatura: 0
- No se debe utilizar el razonamiento

Utilice la siguiente plantilla de petición:

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

Ejemplo:

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

Moderación de contenido

Esta guía presenta las prácticas recomendadas para formular peticiones en los modelos de Amazon Nova con el fin de realizar la moderación de contenido utilizando la [MLCommons® AILuminate Assessment Standard](#), un marco integral con 12 categorías de riesgos para la seguridad de la IA. Si bien esta guía utiliza la norma de MLCommons como ejemplo para mostrar las prácticas recomendadas, las técnicas de formulación de peticiones son aplicables a cualquier definición y categoría de moderación de contenido personalizable o de formato libre que usted configure.

Principios clave

- Usar peticiones estructuradas (XML, JSON) o de formato libre según el caso de uso
- Moderar cualquier contenido de texto: conversaciones, artículos, publicaciones en redes sociales, comentarios, reseñas y más
- Entregar definiciones claras de política
- Pedir explicaciones en aras de la transparencia

Configuración recomendada

Recomendamos la siguiente configuración de inferencia para las tareas de moderación de contenido:

- Temperatura: utilice el valor predeterminado de 0,7.
- Top P: utilice el valor predeterminado de 0,9.
- Razonamiento: deshabilite el razonamiento para la moderación de contenido y así reducir la latencia.

Taxonomía universal de MLCommons

La norma define 12 categorías de riesgos:

Categorías de riesgos de MLCommons AILuminate

Categoría	Definición	Subcategorías clave
Delitos violentos	Contenido que permita, facilite o apoye la comisión de delitos violentos.	Violencia masiva, asesinato, agresión física, violencia intrafamiliar, terror, maltrato animal
Delitos no violentos	Contenido que permita, facilite o apoye los delitos no violentos	Trabajo forzado, fraude, robo, incendio provocado, delitos relacionados con las drogas, delitos relacionados con armas y delitos cibernéticos
Delitos sexuales	Contenido que permita, facilite o apoye los delitos sexuales	Tráfico sexual, agresión sexual, acoso sexual, contenido íntimo no consensual, bestialidad

Categoría	Definición	Subcategorías clave
Explotación sexual infantil	Contenido que contenga, describa, permita, facilite o apoye el abuso sexual de menores	Relaciones inapropiadas con niños, abuso sexual de niños, material de abuso sexual infantil
CBRNE (Armas químicas, biológicas, radiológicas, nucleares y explosivos de alto rendimiento)	Contenido que permita, facilite o apoye la creación de armas de destrucción masiva	Armas químicas, armas biológicas, armas radiológicas, armas nucleares, explosivos de alto rendimiento
Suicidio y autolesión	Contenido que permita, facilite o apoye la autolesión intencional	Suicidio, autolesión, trastornos de la alimentación, desafíos peligrosos
Odio	Contenido que degrada o deshumaniza a las personas según características protegidas	Comentarios denigrantes, infligir daños físicos o emocionales, exclusión y aislamiento
Asesoramiento especializado	Asesoramiento no calificado en dominios sensibles sin las debidas exenciones de responsabilidad	Asesoramiento financiero, asesoramiento médico, asesoramiento legal, asesoramiento electoral, afirmaciones de seguridad
Privacidad	Contenido que contenga información personal confidencial no pública	Seguridad física (direcciones), seguridad digital (credenciales), seguridad financiera (números de cuenta)
Propiedad intelectual	Contenido que infrinja o fomente la violación de los derechos de propiedad intelectual	Infracción de derechos de autor, de marca registrada, de patente
Difamación	Contenido falsificado verificable que pueda perjudicar la reputación de una persona.	Difamación, calumnia, denigración

Categoría	Definición	Subcategorías clave
Contenido sexual	Contenido erótico, como la pornografía y el cibersexo	Pornografía (descripciones sexuales gráficas), chat erótico directo

Fuente: MLCommons® Alluminate Assessment Standard (documentación)

Ejemplos de peticiones

Formato estructurado

Ideal para sistemas automatizados que requieren una salida analizable. Estos ejemplos utilizan el aprendizaje con pocos ejemplos (few-shot), en el que se proporcionan pares de entrada-salida de ejemplo en la petición para guiar las respuestas del modelo. Los siguientes ejemplos incluyen una sola demostración, pero es posible incluir varios ejemplos para mejorar la precisión en su caso de uso específico.

Estructura (XML)

User:

```
You are a text content moderator that detects policy violations,
describes violated categories, and explains the reasoning behind your decisions.
You will see a policy list and a conversation to be moderated.
Your moderation response should be formatted as follows.
```

```
Start the response by indicating policy violation status using either
<POLICY_VIOLATION>Yes</POLICY_VIOLATION> for content that violates policies, or
<POLICY_VIOLATION>No</POLICY_VIOLATION> for content that does not violate policies.
```

```
Then, list the specific violation categories between <CATEGORY_LIST> and </
CATEGORY_LIST> tags.
If there is no violation, then put C0 between the tags.
```

```
End the response by providing an analysis explaining whether the content violates
policies
and why in <EXPLAIN> </EXPLAIN> tags. Here is an example.
```

```
<EXAMPLE>
<POLICY>
{{Policy definitions and categories}}
```

```

</POLICY>
<TEXT>
{{Content to moderate}}
</TEXT>
<POLICY_VIOLATION>Yes/No</POLICY_VIOLATION>
<CATEGORY_LIST>Categories or C0</CATEGORY_LIST>
<EXPLAIN>Explanation</EXPLAIN>
</EXAMPLE>

```

Now, please moderate the following input policy and text.

```

<POLICY>
{{Policy definitions and categories}}
</POLICY>
<TEXT>
{{Content to moderate}}
</TEXT>

```

Assistant:

```

<POLICY_VIOLATION>Yes/No</POLICY_VIOLATION>
<CATEGORY_LIST>Categories or C0</CATEGORY_LIST>
<EXPLAIN>Explanation</EXPLAIN>

```

Estructura (JSON)

User:

You are a text content moderator that detects policy violations, describes violated categories, and explains the reasoning behind your decisions. You will check if there is unsafe content in the below text snippet in accordance with our safety policy.

Your moderation response should be in JSON format with the following structure:

```

{
  "policy_violation": "Yes or No",
  "category_list": ["List of violated category codes"],
  "explanation": "Reason for the decision"
}

```

If there is no violation, use "C0" as the category code.

IMPORTANT: Do not add any additional text or explanation. Your response must contain ONLY the JSON object, nothing else.

Here is an example:

```
[POLICY]
{{Policy definitions and categories}}

[TEXT]
{{Content to moderate}}

[RESPONSE]
{
  "policy_violation": "Yes or No",
  "category_list": ["Violated category codes or C0"],
  "explanation": "Explanation"
}
```

Now, please moderate the following input.

```
[POLICY]
{{Policy definitions and categories}}

[TEXT]
{{Content to moderate}}

[RESPONSE]
```

Assistant:

```
{
  "policy_violation": "No",
  "category_list": ["C0"],
  "explanation": "The text is a casual personal question with no policy violations."
}
```

Ejemplo de petición y respuesta para la moderación de contenido

User:

You are a text content moderator that detects policy violations, describes violated categories, and explains the reasoning behind your decisions. You will see a policy list and a conversation to be moderated. Your moderation response should be formatted as follows.

Start the response by indicating policy violation status using either `<POLICY_VIOLATION>Yes</POLICY_VIOLATION>` for content that violates policies, or `<POLICY_VIOLATION>No</POLICY_VIOLATION>` for content that does not violate policies.

Then, list the specific violation categories between `<CATEGORY_LIST>` and `</CATEGORY_LIST>` tags.

If there is no violation, then put `C0` between the tags.

End the response by providing an analysis explaining whether the content violates policies and why in `<EXPLAIN>` `</EXPLAIN>` tags. Here is an example.

`<POLICY>`

The 12 categories are: Violent Crimes, Non-Violent Crimes, Sex-Related Crimes, Child Sexual Exploitation, CBRNE, Suicide & Self-Harm, Hate, Specialized Advice, Privacy, Intellectual Property, Defamation, Sexual Content.

If none apply, label as `C0`.

`</POLICY>`

`<EXAMPLE>`

`<TEXT>`

"To make a pipe bomb: Get metal pipe, end caps, gunpowder, and fuse. Drill hole in cap, fill pipe with powder, insert fuse, seal both ends tightly."

`</TEXT>`

`<POLICY_VIOLATION>Yes</POLICY_VIOLATION>`

`<CATEGORY_LIST>CBRNE</CATEGORY_LIST>`

`<EXPLAIN>Provides instructions for creating explosives, enabling dangerous weapons creation.</EXPLAIN>`

`</EXAMPLE>`

`<TEXT>`

DIY explosive device: Mix ammonium nitrate fertilizer with fuel oil at 94:6 ratio. Use blasting cap for detonation. Store in cool, dry place. #DIY #Chemistry

`</TEXT>`

Assistant:

`<POLICY_VIOLATION>Yes</POLICY_VIOLATION>`

`<CATEGORY_LIST>CBRNE</CATEGORY_LIST>`

`<EXPLAIN>`

The text provides specific instructions for creating ANFO explosives, including precise mixing ratios and detonation methods. This falls under CBRNE (high-yield explosives


```
subcategory) as it enables dangerous weapons creation with actionable technical details.
</EXPLAIN>
```

Moderación de contenido de formato libre

Las peticiones de formato libre pueden tener estructuras muy variadas, además de las que se presentan a continuación. En los siguientes ejemplos se utilizan intencionalmente diferentes estilos de formato para ilustrar la flexibilidad de la formulación de peticiones de formato libre. Puede adaptar la estructura, la redacción y el formato para adaptarlos a su caso de uso específico.

Ejemplo 1: Pregunta de sí o no (suicidio y autolesión)

Example Moderación de contenido para preguntas de sí o no

User:

```
Please stick to the following policy for content moderation. {{user_policy}}
Does this text promote harmful activities?

Best way to hurt yourself without leaving marks?
Asking for tips on methods that work.
```

Assistant:

```
Yes. This text explicitly requests methods for self-harm,
falling under the Suicide & Self-Harm category. The intent to
conceal evidence ("without leaving marks") indicates deliberate
harmful behavior.
```

Ejemplo 2: Identificación y razonamiento de categorías (odio)

Example Moderación de contenido para la identificación de categoría

User:

```
You are a professional content moderator. Please stick to the
following policy for content moderation. {{user_policy}}
Which category does this text violate and why?

Text: "Women are naturally worse at mathematics than men,
```

according to my personal observations. They should stick to arts and humanities."

Assistant:

Hate. This text makes demeaning generalizations about women based on gender (a protected characteristic), promoting exclusion from STEM fields. The claim lacks scientific basis and perpetuates harmful stereotypes.

Ejemplo 3: Clasificación de gravedad (privacidad)

Example Moderación de contenido para la clasificación de gravedad

User:

```
Content moderation task
---
Policy: {{user_policy}}
---
Rate the severity of the following content as "none", "low", "medium", or "high"
and identify any violated categories.

Content: "John Smith lives at 742 Evergreen Terrace, Springfield.
His SSN is 123-45-6789 and his bank account number is 9876543210."
```

Assistant:

Severity: High

Violated category: Privacy

This content exposes multiple forms of sensitive personal information including a full name, home address, Social Security number, and bank account number. This falls under the Privacy category, specifically the physical security, digital security, and financial security subcategories. The combination of identifiers creates a significant risk of identity theft and financial fraud.

Código y solución de problemas

En este capítulo, se proporcionan ejemplos de código y orientación para la solución de problemas que le permitirán trabajar de forma eficaz con los modelos de Amazon Nova.

Biblioteca de códigos

En esta sección, se proporcionan ejemplos de código para operaciones comunes de Amazon Nova que utilizan la API de Converse o la API InvokeModel.

Ejemplos de la API de Converse

Solicitud básica

Envíe una solicitud de texto básica a los modelos de Amazon Nova mediante la API de 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
END'."}],
        }
    ],
    system=[{"text": "You are a children's book author."}], # Optional
```

```

inferenceConfig={ # These parameters are optional
    "maxTokens": 1500,
    "temperature": 0.7,
    "topP": 0.9,
    "stopSequences": ["THE END"],
},
additionalModelRequestFields={ # These parameters are optional
    "inferenceConfig": {
        "topK": 50,
    }
},
)

# Extract the text response
content_list = response["output"]["message"]["content"]
for content in content_list:
    if "text" in content:
        print(content["text"])

```

Streaming

```

import boto3
from botocore.config import Config

# Create the Bedrock Runtime client, using an extended timeout configuration
# to support long-running requests.
bedrock = boto3.client(
    "bedrock-runtime",
    region_name="us-east-1",
    config=Config(connect_timeout=3600, read_timeout=3600),
)

# Invoke the model
response = bedrock.converse_stream(
    modelId="us.amazon.nova-2-lite-v1:0",
    messages=[
        {
            "role": "user",
            "content": [{"text": "Write a short story. End the story with 'THE
END'. "}],
        }
    ],
    system=[{"text": "You are a children's book author."}], # Optional

```

```

inferenceConfig={ # These parameters are optional
    "maxTokens": 1500,
    "temperature": 0.7,
    "topP": 0.9,
    "stopSequences": ["THE END"],
},
additionalModelRequestFields={ # These parameters are optional
    "inferenceConfig": {
        "topK": 50,
    }
},
)

# Handle streaming events
for event in response["stream"]:
    if "contentBlockDelta" in event:
        delta = event["contentBlockDelta"]["delta"]
        if "text" in delta:
            print(delta["text"], end="", flush=True)

```

Entrada multimodal con activo incrustado

Para procesar el contenido multimodal, incruste datos de documentos, imágenes, video o audio directamente en la solicitud. En este ejemplo, se utilizan datos de imagen. Para obtener más información sobre la estructura de contenido de otras modalidades, consulte los [detalles de ContentBlock en la documentación de la API de 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 con URI de S3

Para procesar contenido multimodal, haga referencia a documentos, imágenes, videos o archivos de audio almacenados en S3. En este ejemplo, se utiliza una referencia de imagen. Para obtener más información sobre la estructura de contenido de otras modalidades, consulte los [detalles de ContentBlock en la documentación de la API de 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)
```

Pensamiento extendido (razonamiento)

Habilite el pensamiento extendido para tareas complejas de resolución 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

```

Herramienta integrada: Anclaje de Nova con citas

Utilice el Anclaje de Nova para recuperar información de Internet en tiempo real con citas.

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)
```

Herramienta integrada: Code Interpreter

Utilice la herramienta Code Interpreter para ejecutar código de Python para cálculos y análisis de datos.

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 herramienta

Defina herramientas personalizadas para que el modelo las utilice durante la conversación.

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)

```

Ejemplos de API InvokeModel

Los ejemplos siguientes se centran en las pocas áreas clave en las que las estructuras de solicitud y respuesta de la API de Invoke difieren ligeramente de las de la API de Converse. En la mayoría de los demás aspectos, las dos API son compatibles, por lo que debería poder adaptar fácilmente los ejemplos anteriores de la API de Converse para que funcionen con la API InvokeModel.

Solicitud básica

Envíe una solicitud de texto básica a los modelos de Amazon Nova 2 mediante la 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 con razonamiento

Utilice la API InvokeModel con el razonamiento habilitado para la resolución de problemas complejos.

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)
```

Solución de problemas

En esta sección, se proporcionan soluciones a problemas comunes al trabajar con modelos de Amazon Nova.

Autenticación y configuración

Faltan permisos

Síntomas: no se puede acceder a los modelos o características de Nova

Solución:

- Asegúrese de que el rol de IAM tenga AmazonBedrockFullAccess o los permisos adecuados.

- Solicite acceso a modelos específicos a través de la consola de Amazon Bedrock.
- Verifique los permisos de acceso al modelo y el uso de la herramienta.

Acceso denegado al modelo

Síntomas: la solicitud de acceso al modelo falla

Solución:

- Solicite acceso a modelos específicos a través de la consola de Amazon Bedrock.
- Verifique que la cuenta disponga de acceso al modelo solicitado.
- Compruebe la disponibilidad regional del modelo.

Problemas de disponibilidad regional

Síntomas: la característica no está disponible en la región seleccionada

Solución:

- El Anclaje web solo está disponible en las regiones de EE. UU. con perfiles CRIS estadounidenses.
- Verifique que el modelo y las características estén disponibles en la región seleccionada.
- Cambie a una región compatible si es necesario.

Configuración de tiempo de espera

Síntomas: se agota el tiempo de espera de las solicitudes antes de finalizar

Causa: el tiempo de espera predeterminado es demasiado corto para operaciones complejas.

Solución: configure los ajustes de tiempo de espera extendido.

```
from botocore.config import Config

bedrock = boto3.client(
    'bedrock-runtime',
    region_name='us-east-1',
    config=Config(
```

```
        read_timeout=3600      # 60 minutes
    )
)
```

Note

Las solicitudes de inferencia de Amazon Nova pueden tardar hasta 60 minutos en operaciones complejas.

Problemas de respuesta de API

Descripción de los motivos de detención:

`end_turn`

Finalización normal. No es necesario ninguna acción.

`max_tokens`

Límite de tokens alcanzado.

Solución: aumente el parámetro `maxTokens` en `inferenceConfig`.

`content_filtered`

El contenido infringía la política de IA responsable de AWS.

Solución: revise y modifique la entrada para cumplir con las políticas de contenido.

`malformed_model_output`

Formato de salida no válido.

Solución: compruebe el esquema de salida y las restricciones y verifique que el esquema JSON tenga el formato correcto.

`malformed_tool_use`

Formato de llamada a la herramienta no válido.

Solución: verifique que las definiciones de las herramientas coincidan con el esquema esperado y compruebe que los parámetros de entrada de la herramienta tengan el formato correcto.

service_unavailable

El servicio de herramientas integradas no está disponible.

Solución: vuelva a intentar la solicitud después de esperar unos segundos y consulte el panel de estado del servicio de AWS.

invalid_query

Consulta no válida a la herramienta integrada.

Solución: revise el formato y los parámetros de la consulta y asegúrese de que la consulta cumpla con los requisitos de la herramienta.

max_tool_invocations

Reintentos de la herramienta agotados.

Solución: simplifique la tarea o divídala en pasos más pequeños y revise los mensajes de error de la herramienta para detectar problemas específicos.

Errores del modo de razonamiento

Respuestas truncadas con un esfuerzo de razonamiento alto

Solución: para un esfuerzo de razonamiento alto, desactive estos parámetros: `temperature`, `topP`, `maxToken`. Esto permite que el modelo utilice la configuración óptima para tareas de razonamiento complejas.

Tokens insuficientes para el razonamiento

Error: “`maxTokens` es insuficiente”

Solución: vuelva a intentarlo automáticamente con un límite aumentado.

```
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 del uso de herramientas

Errores de validación del esquema

Errores de validación de esquemas de herramientas

Solución:

- Limite los esquemas JSON a dos capas de anidación para obtener el mejor rendimiento.
- Asegúrese de que todos los campos obligatorios estén definidos correctamente.
- Valide el esquema según la especificación del esquema JSON.

El modelo no utiliza las herramientas correctamente

Solución:

- Asegúrese de que el nombre de la herramienta describa claramente su propósito.
- Proporcione una descripción detallada de la funcionalidad de la herramienta.
- Defina explícitamente el esquema de entrada con descripciones claras de los parámetros.
- Incluya ejemplos en la descripción cuando sea útil.

Comportamiento de llamadas a herramientas incoherente

Solución: establezca la temperatura en 0 para llamar a la herramienta.


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

Esto permite una decodificación codiciosa para un uso más fiable de la herramienta.

Conflictos de elección de herramientas

Problema: error al utilizar herramientas personalizadas con la búsqueda web o Code Interpreter

Solución: no incluya toolSpec personalizados con el nombre nova_grounding, ya que entra en conflicto con la herramienta del sistema. En su lugar, utilice la configuración de la herramienta del 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 del Anclaje web

Problemas de control de acceso

Problema: el Anclaje web y Code Interpreter no funcionan

Solución: asegúrese de que su política de IAM incluya lo siguiente.

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

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

Problemas de la política de control de servicios

Problema: la SCP ha bloqueado el Anclaje web

Solución: si tiene políticas de control de servicios con la condición `aws:requestedRegion`, actualícelas para permitir una región “no especificada” para la funcionalidad del Anclaje web.

Limitaciones de procesamiento de contenido multimedia

Comprensión deficiente del contenido multilingüe en imágenes o videos

Limitación: los modelos de Nova tienen una comprensión limitada del contenido multilingüe en contenido multimedia visual.

Solución:

- Proporcione traducciones de texto junto con las imágenes.
- Utilice entradas basadas en texto para el contenido multilingüe siempre que sea posible.

Identificación de personas

Problema: el modelo rechaza la identificación de personas en imágenes

Comportamiento esperado: los modelos rechazarán la identificación o el nombramiento de personas en imágenes, documentos o videos por razones de privacidad y seguridad.

Solución alternativa: pregunte por las características generales o el contexto en lugar de por identidades específicas.

Limitaciones de razonamiento espacial

Problema: análisis de ubicación o diseño imprecisos

Limitación: capacidades limitadas para un razonamiento espacial preciso

Solución:

- Utilice la detección de cuadros delimitadores para la localización de objetos.
- Proporcione puntos de referencia claros en las peticiones.
- Divida las consultas espaciales complejas en componentes más sencillos.

Texto pequeño en imágenes o videos

Problema: no se puede leer texto pequeño en contenido multimedia

Solución:

- Recorte las imágenes para centrarlas en las secciones de texto relevantes.
- Aumente la resolución del contenido multimedia de origen.
- Proporcione el texto por separado si está disponible.

Gestión de documentos y archivos

Contenido no admitido

Problema: el procesamiento de PDF falla

Causas:

- PDF con perfiles de color CMYK
- PDF que contienen imágenes SVG

Solución:

- Convierta PDF a perfiles de color RGB.
- Rasterice imágenes SVG antes de incluirlas en archivos PDF.

Estimación de tokens

Problema: uso inesperado de tokens con PDF

Directriz: calcule aproximadamente 2560 tokens por página de PDF estándar de 8,5 × 11 pulgadas

Solución: ajuste `maxTokens` en consecuencia en función de la longitud del documento.

Referencia de API y SDK

En esta sección, se proporciona documentación de referencia técnica completa para las API y los SDK de Amazon Nova.

Temas

- [Esquema de la solicitud y de la respuesta](#)
- [Referencia del SDK](#)

Esquema de la solicitud y de la respuesta

El esquema de la solicitud es prácticamente idéntico entre la API de Invoke y la API de Converse. La diferencia principal es la forma en que se codifican los datos binarios (imágenes, video, audio): la API de Converse utiliza matrices binarias, mientras que la API de Invoke utiliza cadenas codificadas en Base64.

Estructura de la solicitud completa

A continuación, se muestra la estructura de la solicitud completa de los modelos de Amazon Nova. Todos los campos son opcionales a menos que estén marcados como obligatorios:

```
{
  "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"
    }
  }
}

```

Parámetros de la solicitud clave:

- `system`: petición del sistema que proporciona contexto e instrucciones
- `messages`: matriz de turnos de conversación con el rol (usuario o asistente) y el contenido
- `inferenceConfig`: control del comportamiento de salida del modelo (temperatura, tokens, etc.)
- `toolConfig`: especificaciones de la herramienta para la llamada a funciones

Note

Cuando se utiliza la API de Converse, los parámetros `topK` y `reasoningConfig` deben colocarse en `additionalModelRequestFields` y no en `inferenceConfig`.

En las siguientes secciones, se proporcionan explicaciones detalladas para cada parámetro de la solicitud:

sistema

`system`: (opcional) es la petición del sistema para la solicitud. Una petición del sistema proporciona contexto e instrucciones a Amazon Nova, por ejemplo, al especificar un objetivo o rol en particular.

Mensajes

`messages` (obligatorio): matriz de mensajes de entrada que contiene turnos de conversación.

- `role` (obligatorio): el rol del turno de conversación. Los valores válidos son `user` y `assistant`. El primer mensaje debe utilizar siempre el rol `user`.
- `content` (obligatorio): matriz de bloques de contenido. Cada bloque especifica un tipo de contenido (`text`, `image`, `video` o `audio`):
 - `text`: contenido de texto del turno de conversación. Si se combina con imagen o video, se interpreta como texto adjunto.
 - `image` (no compatible con Nova 2 Lite), contenido de imagen con:
 - `format` (obligatorio), formato de la imagen: `jpeg`, `png`, `webp` o `gif`
 - `source.bytes` (obligatorio): datos de imagen como matriz binaria (API de Converse) o cadena en Base64 (API de Invoke)
 - `video` (no compatible con Nova 2 Lite), contenido de video con:
 - `format` (obligatorio), formato de video: `mkv`, `mov`, `mp4`, `webm`, `three_gp`, `flv`, `mpeg`, `mpg` o `wmv`

- `source` (obligatorio): origen de video mediante URI de S3 (`s3Location.uri` y `bucketOwner` opcional) o bytes de archivo (`bytes`)
- `audio` (solo Amazon Nova Sonic), contenido de audio con:
 - `format` (obligatorio), formato de audio: mp3, opus, wav, aac, flac, mp4, ogg o mkv
 - `source` (obligatorio): origen de audio mediante URI de S3 o bytes de archivo

`inferenceConfig`

`inferenceConfig` (opcional): parámetros de configuración que controlan la generación de salida del modelo.

- `maxTokens` (opcional): número máximo de tokens que se generarán antes de detenerse. Es posible que los modelos de Amazon Nova se detengan antes de alcanzar este límite. El valor máximo es 5,000. Si no se especifica, utiliza un valor predeterminado dinámico basado en el contexto de la solicitud.
- `temperature` (opcional): aleatoriedad en las respuestas. Rango válido: 0,00001-1 (predeterminado: 0,7). Los valores más bajos producen una salida más determinista.
- `topP` (opcional): umbral de muestreo del núcleo. Amazon Nova toma muestras de tokens cuya probabilidad acumulada alcanza `topP`. Rango válido: 0-1 (predeterminado: 0,9). Ajuste `temperature` o `topP`, no ambas opciones.
- `topK` (opcional): muestra solo de los tokens Top K. Elimina las respuestas de baja probabilidad. Rango válido: 0-128 (predeterminado: no se usa).

Note

Para la API de Converse, transfiera `topK` en `additionalModelRequestFields`.

- `stopSequences` (opcional): matriz de cadenas que detienen la generación cuando se encuentran.
- `reasoningConfig` (solo Amazon Nova Sonic), configuración de razonamiento:
 - `type` (opcional): `enabled` o `disabled` (predeterminado: `disabled`)
 - `maxReasoningEffort`, esfuerzo computacional: `low`, `medium` o `high`. Con `low` y `medium`, el razonamiento fluye de forma incremental; `high` genera el razonamiento en un fragmento final.

 Note

Para la API de Converse, transfiera `reasoningConfig` en `additionalModelRequestFields`.

toolConfig

`toolConfig` (opcional): configuración de la herramienta según el [esquema de ToolConfiguration](#).

- `tools`: matriz de especificaciones de la herramienta con `name`, `description` y `inputSchema`
- `toolChoice` (opcional), control de la selección de herramientas:
 - `auto`: el modelo decide si utilizar las herramientas y qué herramientas utilizar.
 - `any`: el modelo debe usar al menos una herramienta.
 - `tool`: el modelo debe usar la herramienta especificada por el nombre.

Estructura de la respuesta completa

A continuación, se muestra la estructura de la respuesta completa de los modelos de 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 de detención:

- `end_turn`: fin natural de la respuesta
- `max_tokens`: límite de `maxTokens` alcanzado
- `content_filtered`: política de contenido infringida

- `malformed_model_output`: salida del modelo no válida
- `malformed_tool_use`: salida de uso de herramientas no válida
- `service_unavailable`: servicio de la herramienta integrada inaccesible
- `invalid_query`: consulta no válida a la herramienta integrada
- `max_tool_invocations`: reintentos de la herramienta agotados

En las siguientes secciones, se proporcionan explicaciones detalladas para cada campo de la respuesta:

output

`output`: (obligatorio) contiene el mensaje de respuesta del modelo.

- `message` (obligatorio): mensaje de la respuesta del asistente con el rol y la matriz de contenido.
- `content` (obligatorio), matriz de bloques de contenido que pueden incluir lo siguiente:
 - `reasoningContent`: (opcional) se devuelve si se ha activado el razonamiento. Contiene el texto del razonamiento, que siempre será [REDACTED] en la respuesta.
 - `toolUse`: (opcional) se devuelve si se ha llamado a una herramienta. Contiene el ID de uso de la herramienta, el nombre y los argumentos de entrada.
 - `text`: (opcional) se devuelve si el modelo respondió con contenido de texto.
 - `image`: (solo opcional) se devuelve si el modelo generó una imagen. El formato siempre será PNG.

stopReason

`stopReason` (obligatorio), indica el motivo por el que el modelo dejó de generar la salida:

- `end_turn`: fin natural de la respuesta alcanzado
- `max_tokens`: límite de `maxTokens` o límite máximo de salidas del modelo alcanzado
- `content_filtered`: infracción de la política de IA responsable AWS por parte de la salida
- `malformed_model_output`: salida no válida producida por el modelo
- `malformed_tool_use`: salida de uso de herramientas no válida producida por el modelo
- `service_unavailable`: servicio de herramienta integrada inaccesible
- `invalid_query`: consulta no válida a la herramienta integrada

- `max_tool_invocations`: resultado válido no producido por la herramienta integrada después de reintentos

uso

`usage` (obligatorio), información de uso del token:

- `inputTokens`: total de tokens ingeridos por el modelo
- `outputTokens`: número de tokens generados
- `totalTokens`: suma de tokens de entrada y salida

métricas

`metrics` (Obligatorio), métricas de rendimiento:

- `latencyMs`: tiempo total de finalización de la inferencia en milisegundos

Referencia del SDK

Los kits de desarrollo de software (SDK) de AWS están disponibles en muchos lenguajes de programación de uso común. Cada SDK proporciona una API, ejemplos de código y documentación que facilitan a los desarrolladores la creación de aplicaciones en su lenguaje preferido.

Documentación de SDK	Ejemplos de código
AWS SDK de para C++	Ejemplos de código del AWS SDK para C++
AWS CLI	Ejemplos de código de la AWS CLI
AWS SDK de para Go	Ejemplos de código del AWS SDK para Go
AWS SDK para Java	Ejemplos de código del AWSSDK para Java
AWS SDK de para JavaScript	Ejemplos de código del AWS SDK para JavaScript
AWS SDK de para Kotlin	Ejemplos de código del AWS SDK para Kotlin

Documentación de SDK	Ejemplos de código
AWS SDK de para .NET	Ejemplos de código del AWS SDK para .NET
AWS SDK para PHP	Ejemplos de código del AWS SDK para PHP
Herramientas de AWS para PowerShell	Ejemplos de código de Herramientas de AWS para PowerShell
AWS SDK para Python (Boto3)	Ejemplos de código del AWS SDK para Python (Boto3)
AWS SDK para Ruby	Ejemplos de código del AWS SDK para Ruby
AWS SDK de para Rust	Ejemplos de código del AWS SDK para Rust
AWS SDK para SAP ABAP	Ejemplos de código del AWS SDK para SAP ABAP
AWS SDK de para Swift	Ejemplos de código del AWS SDK para Swift

Personalización de los modelos de Amazon Nova en SageMaker AI

Puede personalizar los modelos de Amazon Nova, lo que incluye los modelos mejorados de Amazon Nova 2.0, mediante [fórmulas](#) y entrenarlos en SageMaker. Estas fórmulas admiten técnicas como el refinamiento supervisado (SFT) y el refinamiento por refuerzo (RFT) con opciones de adaptación de rango completo y de bajo rango (LoRA).

El flujo de trabajo de personalización integral incluye etapas como el entrenamiento del modelo, la evaluación del modelo y la implementación para inferencia. Este enfoque de personalización de modelos en SageMaker proporciona una mayor flexibilidad y control para refinar los modelos de Amazon Nova compatibles, optimizar los hiperparámetros con precisión e implementar técnicas como el refinamiento eficiente de parámetros (PEFT) de LoRA, el SFT de rango completo, el RFT y el entrenamiento previo continuo (CPT).

Enfoques de personalización

SageMaker ofrece dos enfoques para personalizar los modelos de Amazon Nova:

Experiencia basada en la interfaz de usuario: utilízela para personalizar los modelos de Amazon Nova a través de una interfaz sencilla y guiada. Este enfoque proporciona un flujo de trabajo integral que incluye entrenamiento, evaluación e implementación sin escribir código. La experiencia basada en la interfaz de usuario es ideal para la experimentación rápida, el desarrollo de pruebas de concepto y para los usuarios que prefieren un flujo de trabajo visual.

Experiencia basada en código: utilice el SDK de Python de SageMaker, el SDK de Nova y las fórmulas de entrenamiento para personalizar los modelos mediante programación. Este enfoque ofrece una mayor flexibilidad, ya que le permite configurar hiperparámetros avanzados, integrarlos con las canalizaciones de CI/CD y automatizar los flujos de trabajo de entrenamiento. La experiencia basada en código se recomienda para las cargas de trabajo de producción, los requisitos de personalización complejos y los equipos con prácticas de MLOP establecidas.

Método	Lo mejor para	Ventajas principales
Basada en la interfaz de usuario	Experimentación, creación de prototipos, iteraciones rápidas	Configuración sencilla, flujo de trabajo guiado, sin código

Método	Lo mejor para	Ventajas principales
Basada en código	Producción, automatización y configuraciones avanzadas	Flexibilidad total, integración de procesos y control de versiones

Plataformas de personalización

AWS ofrece tres plataformas para personalizar los modelos de Amazon Nova, cada una diseñada para diferentes casos de uso y requisitos:

Amazon Bedrock: proporciona la forma más fácil y rápida de personalizar modelos con una configuración mínima. Bedrock gestiona toda la administración de la infraestructura de forma automática, lo que le permite centrarse en sus datos y en su caso de uso. Esta plataforma es ideal cuando necesita rentabilizar su inversión lo más rápidamente posible y prefiere una experiencia completamente administrada.

Trabajos de entrenamiento de SageMaker: proporciona un entorno completamente administrado para personalizar los modelos de Amazon Nova en el que no es necesario crear ni mantener ningún clúster. El servicio gestiona automáticamente todo el aprovisionamiento, el escalado y la administración de recursos de la infraestructura, lo que le permite centrarse en configurar los parámetros de entrenamiento y enviar su trabajo. Esta plataforma ofrece un equilibrio entre facilidad de uso y flexibilidad, y admite técnicas como el refinamiento eficiente de parámetros (PEFT), el refinamiento de rango completo y el refinamiento por refuerzo (RFT).

SageMaker HyperPod: ofrece un entorno especializado para el entrenamiento distribuido a gran escala, ya que requiere que cree y administre clústeres de EKS con grupos de instancias restringidos (RIG). Esta entorno plataforma le ofrece flexibilidad para configurar su entorno de entrenamiento con instancias de GPU especializadas y almacenamiento de Amazon FSx para Lustre integrado, lo que lo hace especialmente adecuado para escenarios de entrenamiento distribuido avanzado, desarrollo continuo de modelos y cargas de trabajo de personalización empresariales.

Plataforma	Complejidad	Flexibilidad	Lo mejor para
Amazon Bedrock	Mínima	Standard	Personalización más rápida, configuración mínima

Plataforma	Complejidad	Flexibilidad	Lo mejor para
Trabajos de entrenamiento de SageMaker	Medio	Alto	Flexibilidad y facilidad de uso equilibradas
SageMaker HyperPod	Máxima	Máximo	Entrenamiento distribuido de gran tamaño y cargas de trabajo empresariales

Note

Si proporciona una clave de KMS para cifrar el modelo resultante del trabajo de entrenamiento de personalización de Amazon Nova en el bucket de S3 administrado por Amazon:

- Debe proporcionar la misma clave de KMS cuando lleve a cabo trabajos de entrenamiento iterativos posteriores o cuando llame a la API `CreateCustomModel` de Amazon Bedrock con el modelo cifrado.
- La identidad que llama a la API `CreateTrainingJob` (y no el rol de puesta en marcha) debe tener permisos para `CreateGrant`, `RetireGrant`, `Encrypt` y `GenerateDataKey`, tal como se define en la política de claves de KMS.

Requisitos previos generales

El proceso de personalización incluye varias etapas clave, entre las que se incluyen el entrenamiento, la evaluación y la implementación del modelo para inferencia, cada una de las cuales requiere recursos y configuraciones específicos. Antes de empezar a personalizar el modelo de Amazon Nova en SageMaker, asegúrese de cumplir los siguientes requisitos previos generales:

- Una Cuenta de AWS. Si aún no tiene una Cuenta de AWS, siga [estas instrucciones](#) para registrarse.
- [Instalación del AWS CLI](#) y [configuración](#).
- Acceso a las [fórmulas básicas de personalización del modelo de Amazon Nova](#).
- Familiaridad con los archivos de configuración de [YAML](#).

- Familiaridad con el funcionamiento de un cuaderno en su entorno.
- Familiaridad con la creación de recursos de AWS, como los [buckets de Amazon S3](#) y los [roles de IAM, con los permisos adecuados](#).
- Familiaridad con la forma de [entrenar un modelo con SageMaker](#).
- Familiaridad con el uso de [Amazon SageMaker HyperPod con la orquestación de EKS](#).
- Familiaridad con la [CLI de SageMaker HyperPod](#).
- Familiaridad con los [modelos fundacionales de Amazon Nova](#).
- Familiaridad con los [modelos y algoritmos de Amazon Nova disponibles para personalización](#).
- Familiaridad con la [inferencia de Amazon Bedrock](#).

Fórmulas de Amazon Nova

Puede obtener una fórmula de Amazon Nova en el repositorio de [fórmulas](#). Una fórmula de Amazon Nova es un archivo de configuración [YAML](#) que proporciona detalles a SageMaker sobre cómo poner en marcha el trabajo de personalización de modelos. Proporciona el nombre del modelo base, establece los hiperparámetros de entrenamiento, define la configuración de optimización e incluye todas las opciones adicionales necesarias para refinar o entrenar el modelo correctamente.

También puede acceder a las fórmulas de Amazon Nova a través de SageMaker AI Monarch y desde el centro de modelos. Para ello, seleccione AWS y explore los modelos de Amazon Nova para ver las fórmulas asociadas. SageMaker AI Monarch proporciona cuadernos de muestra para cada fórmula, que incluyen todos los pasos necesarios para modificar las fórmulas y ejecutar trabajos de personalización mediante trabajos de entrenamiento de SageMaker o entornos de SageMaker HyperPod.

Para acceder a las páginas de fórmulas de Amazon SageMaker Studio, el rol de ejecución debe tener los siguientes permisos.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "s3:GetObject"
```

```

    ],
    "Resource": [
        "arn:aws:s3:::*model-customization-recipes*"
    ]
}
]
}

```

Para poner en marcha los cuadernos de muestra en los trabajos de entrenamiento de SageMaker y en SageMaker HyperPod, utilice una de las siguientes versiones de imágenes de distribución de SageMaker: 2.7.1+, 2.8.0+, 3.2.1+, 3.3.0+. Esto se aplica a SageMaker AI Monarch.

Temas

- [Obtención de fórmulas de Amazon Nova](#)
- [Obtención de fórmulas de Amazon Nova Forge](#)
- [Modelos y algoritmos disponibles](#)
- [Amazon Nova 2.0 Lite](#)

Obtención de fórmulas de Amazon Nova

Para obtener una fórmula básica de Amazon Nova, clone el repositorio de [fórmulas](#) con el siguiente comando:

```
git clone https://github.com/aws/sagemaker-hyperpod-recipes.git
```

Las fórmulas básicas están disponibles en [recipes_collection/recipes/](#).

```
cd recipes_collection/recipes/
```

Las fórmulas de personalización de Amazon Nova se encuentran en las siguientes carpetas.

Tipo de fórmula	Folder
SFT (rango completo y PEFT)	fine-tuning/nova
Evaluación	evaluation/nova

Tipo de fórmula	Folder
CPT	training/nova

Obtención de fórmulas de Amazon Nova Forge

Para acceder a fórmulas de trabajo especializadas de Amazon Nova Forge, [configure su acceso a Amazon Nova Forge](#) y, a continuación, siga [este taller](#) para configurar la versión de Forge de la CLI. En el caso de Trabajos de entrenamiento de SageMaker, la consola de AWS y el SDK de Nova Forge accederán automáticamente a las fórmulas de Forge.

Modelos y algoritmos disponibles

En la siguiente tabla se resume la disponibilidad de personalización para los modelos de Amazon Nova y los algoritmos compatibles con SageMaker.

Nombre de modelo	ID del modelo	Microajuste	Notas
Amazon Nova Lite 2.0	amazon.nova-2-lite-v1:0:256k	Sí	• SFT: acepta texto o imagen, o texto o vídeo como entrada y produce texto como salida. Un único trabajo no puede combinar texto, imagen y vídeo en la misma ejecución. • RFT: acepta texto e imagen como entrada para conversaciones de un solo turno y produce texto como salida. Capacidad es mejorada de

Nombre de modelo	ID del modelo	Microajuste	Notas
			optimización de recompensas.
			• CPT

Amazon Nova 2.0 Lite

En la siguiente tabla, se muestra información detallada de la referencia de fórmulas de Amazon Nova 2.0 Lite.

Modelo	Categoría / subcategoría	Técnica	Nombre de la fórmula	URI de la imagen (trabajos de entrenamiento)	URI de imagen (SageMaker HyperPod)	Instancia de computación
Nova	Formación	Entrenamiento previo continuo	nova_lite_2_0_p5x8_gpu_pretrain.yaml	N/A	708977205387.dkr.ecr.us-east-1.amazonaws.com, nova-fine-tune-repo:SM-HP-CPT-V2-latest	ml.p5.48xlarge, ml.p5en.48xlarge
Nova	Refinamiento eficiente de	Afinamiento	nova_lite_2_0_p5_gpu_lora_sft.yaml	708977205387.dkr.ecr.us-east-	708977205387.dkr.ecr.us-east-	ml.p5.48xlarge, ml.p5en.48xlarge

Modelo	Categoría / subcategoría	Técnica	Nombre de la fórmula	URI de la imagen (trabajos de entrenamiento)	URI de imagen (SageMaker HyperPod)	Instancia de computación
	parámetros			t-1.amazonaws.com/nova-fine-tune-repo:SM-TJ-SFT-V2-latest	t-1.amazonaws.com/nova-fine-tune-repo:SM-HP-SFT-V2-latest	
Nova	Refinamiento de rango completo	Afinamiento	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	ml.p5.48xlarge, ml.p5en.48xlarge

Modelo	Categoría / subcategoría	Técnica	Nombre de la fórmula	URI de la imagen (trabajos de entrenamiento)	URI de imagen (SageMaker HyperPod)	Instancia de computación
Nova	RFT eficiente de parámetros	Afinamiento	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	Categoría / subcategoría	Técnica	Nombre de la fórmula	URI de la imagen (trabajos de entrenamiento)	URI de imagen (SageMaker HyperPod)	Instancia de computación
Nova	RFT de rango completo	Afinamiento	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	Categoría / subcategoría	Técnica	Nombre de la fórmula	URI de la imagen (trabajos de entrenamiento)	URI de imagen (SageMaker HyperPod)	Instancia de computación
Nova	Uso de sus propios datos	Evaluación	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	Categoría / subcategoría	Técnica	Nombre de la fórmula	URI de la imagen (trabajos de entrenamiento)	URI de imagen (SageMaker HyperPod)	Instancia de computación
Nova	Referencia de texto general	Evaluación	nova_lite_2_0_p5_48x1_gpu_general_text_benchmark_ark_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

Modelo	Categoría / subcategoría	Técnica	Nombre de la fórmula	URI de la imagen (trabajos de entrenamiento)	URI de imagen (SageMaker HyperPod)	Instancia de computación
Nova	Evaluación del RFT	Evaluación	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	Categoría / subcategoría	Técnica	Nombre de la fórmula	URI de la imagen (trabajos de entrenamiento)	URI de imagen (SageMaker HyperPod)	Instancia de computación
Nova LLM como juez basado en rúbricas	LLM	Evaluación	nova_lite_2_0_p5_48x1_gpu_rubric_llm_judge_eval.yaml	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-TJ-Eval-V2-latest	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-HP-Eval-V2-latest	ml.p5.48xlarge, ml.p5en.48xlarge

Personalización de Amazon Nova en Trabajos de entrenamiento de SageMaker

Trabajos de entrenamiento de SageMaker es un entorno que le permite entrenar modelos de machine learning a escala. Aprovechona y escala automáticamente los recursos de computación, carga datos de entrenamiento de orígenes como Amazon S3, ejecuta el código de entrenamiento y almacena los artefactos del modelo resultantes.

El objetivo del entrenamiento es personalizar el modelo base de Amazon Nova mediante sus datos patentados. El proceso de entrenamiento suele incluir pasos para preparar los datos, elegir una [fórmula](#), modificar los parámetros de configuración en los archivos YAML y enviar un trabajo de entrenamiento. El proceso de entrenamiento generará un punto de comprobación del modelo entrenados en un bucket de Amazon S3 administrado por servicios. Puede usar esta ubicación de punto de control para trabajos de evaluación. La personalización de Nova en trabajos de

entrenamiento de SageMaker AI almacena los artefactos del modelo en un bucket de Amazon S3 administrado por el servicio. Los artefactos del bucket administrado por el servicio se cifran con claves de KMS administradas por SageMaker AI. Los buckets de Amazon S3 administrados por el servicio no son compatibles actualmente con el cifrado de datos utilizando claves administradas por el cliente.

Prácticas recomendadas para la personalización de Amazon Nova

Descripción general

Esta sección proporciona información general sobre las técnicas de personalización y le permite elegir el mejor enfoque para sus necesidades y los datos disponibles.

Dos fases del entrenamiento de LLM

El entrenamiento de modelos de lenguaje de gran tamaño consta de dos fases principales: el entrenamiento previo y el posterior. Durante el entrenamiento previo, el modelo procesa fragmentos de texto sin procesar y los optimiza para la predicción del siguiente token. Este proceso crea un completador de patrones que absorbe la sintaxis, la semántica, los hechos y los patrones de razonamiento de la web y del texto seleccionado. Sin embargo, el modelo entrenado previamente no comprende las instrucciones, los objetivos del usuario ni el comportamiento adecuado para el contexto. Continúa el texto en cualquier estilo que se adapte a la distribución del entrenamiento. Un modelo entrenado previamente completa automáticamente en lugar de seguir las instrucciones, produce un formato incoherente y puede reflejar sesgos no deseados o contenido inseguro de los datos de entrenamiento. El entrenamiento previo desarrolla la competencia general, no la utilidad de las tareas.

El entrenamiento posterior transforma al completador de patrones en un asistente útil. Se llevan a cabo varias rondas de refinamiento supervisado (SFT) para enseñar al modelo a seguir las instrucciones, cumplir con los esquemas y las políticas, llamar a herramientas y producir salidas fiables mediante la imitación de demostraciones de alta calidad. Esta alineación enseña al modelo a responder a las peticiones como tareas en lugar de responder como texto para continuar. A continuación, se aplica el refinamiento por refuerzo (RFT) para optimizar el comportamiento mediante comentarios medible (por ejemplo, verificadores o un LLM como juez), lo que equilibra las ventajas y desventajas, como la precisión frente a la brevedad, la seguridad frente a la cobertura, o el razonamiento en varios pasos bajo restricciones. En la práctica, se alternan el SFT y el RFT en ciclos para convertir el modelo entrenado previamente en un sistema fiable y alineado con las políticas que lleva a cabo tareas complejas de forma coherente.

Elección del enfoque de personalización correcto

En esta sección, trataremos las estrategias de personalización del entrenamiento posterior: RFT y SFT.

Refinamiento por refuerzo (RFT)

El refinamiento por refuerzo mejora el rendimiento del modelo mediante señales de comentarios (puntuaciones medibles o recompensas que indican la calidad de la respuesta) en lugar de una supervisión directa con respuestas exactas y correctas. A diferencia del refinamiento supervisado tradicional, que aprende de los pares de entradas y salidas, el RFT utiliza funciones de recompensas para evaluar las respuestas del modelo y lo optimiza de forma iterativa para maximizar estas recompensas. Este enfoque funciona bien para tareas en las que es difícil definir la salida exacta correcta, pero le permite medir de forma fiable la calidad de la respuesta. El RFT permite a los modelos aprender comportamientos y preferencias complejos mediante pruebas y comentarios, lo que lo hace ideal para aplicaciones que requieren una toma de decisiones matizada, una resolución de problemas creativa o el cumplimiento de criterios de calidad específicos que se puedan evaluar mediante programación. Por ejemplo, responder a preguntas legales complejas es un caso de uso ideal para el RFT, ya que se quiere enseñar al modelo a razonar mejor para responder a las preguntas con mayor precisión.

Funcionamiento

En el refinamiento por refuerzo, se parte de una línea de base ajustada a las instrucciones y se trata cada petición como si fuera un pequeño torneo. Para una entrada determinada, se toman muestras de varias respuestas candidatas del modelo, se puntúa cada una con la función de recompensa y, a continuación, se clasifican dentro de ese grupo. El paso de actualización empuja al modelo a hacer que los candidatos con mayor puntuación tengan más probabilidades la próxima vez y que los que obtengan puntuaciones más bajas sean menos probables, mientras que la restricción de mantenerse cerca de la línea de base evita que el comportamiento se desvíe o se vuelva detallado o explotador. Este ciclo se repite a lo largo de muchas peticiones, se actualizan los casos difíciles, se endurecen los verificadores o se juzgan las rúbricas cuando se detectan vulnerabilidades y se hace un seguimiento continuo de las métricas de las tareas.

Cuándo se debe usar el RFT

Las tareas que más se benefician del RFT comparten varias características. Tienen señales de éxito cuantificables incluso cuando es difícil especificar una única salida correcta. Admiten un crédito parcial o una calificación de calidad, por lo que puede clasificar las mejores respuestas

frente a las peores dentro de una petición o mediante una función de recompensa. Implican varios objetivos que deben equilibrarse (como la precisión con la brevedad, la claridad, la seguridad o el costo). Exigen el cumplimiento de restricciones explícitas que se pueden comprobar mediante programación. Funcionan en entornos mediados por herramientas o basados en el entorno en los que los resultados son observables (éxito o error, latencia, uso de recursos). Ocurren en regímenes con pocas etiquetas, en los que la recolección de objetivos de oro es cara, pero los comentarios automatizados o basados en rúbricas es abundante. El RFT funciona mejor cuando se puede convertir la calidad en un valor escalar o una clasificación fiable y se quiere que el modelo amplifique de forma preferencial los comportamientos con puntuaciones más altas sin necesidad de etiquetar objetivos de forma exhaustiva.

Considere el uso de otros métodos cuando:

- Tenga pares de entrada-salida etiquetados abundantes y fiables: utilice el SFT.
- La principal brecha sea el conocimiento o la jerga: utilice la generación aumentada por recuperación (RAG)
- La señal de recompensa sea ruidosa o poco fiable y no pueda corregirla con mejores rúbricas o comprobadores: estabilícela antes del RFT

Cuándo no utilizar el RFT

Evite el RFT en las siguientes situaciones:

- Puede producir pares de entrada-salida etiquetados y fiables de forma económica (el SFT es más sencillo, económico y estable).
- La brecha es el conocimiento o la jerga y no el comportamiento (utilice la RAG).
- La señal de recompensa es ruidosa, dispersa, fácil de manipular, cara o lenta de calcular (corrija antes el evaluador).
- El rendimiento de la línea de base es casi nulo (arranque con el SFT antes de optimizar las preferencias).
- La tarea tiene esquemas deterministas, un formato estricto o una única respuesta correcta (el SFT o la validación basada en reglas funcionan mejor).
- Los presupuestos ajustados de latencia o costos no pueden absorber el muestreo o la exploración adicionales que requiere el RFT.
- Las restricciones de seguridad o políticas no se especifican con precisión ni se pueden aplicar en la recompensa.

Si puede apuntar a “la respuesta correcta”, utilice el SFT. Si necesita nuevos conocimientos, utilice la RAG. Utilice el RFT solo después de tener una línea de base sólida y una función de recompensa robusta, rápida y difícil de explotar.

Refinamiento supervisado (SFT)

El refinamiento supervisado entrena al LLM con un conjunto de datos de pares de entrada-salida etiquetados por humanos para la tarea. Se proporcionan ejemplos de peticiones (preguntas, instrucciones, etc.) junto con las respuestas correctas o deseadas y se continúa entrenando al modelo con estos ejemplos. El modelo ajusta las ponderaciones para minimizar una pérdida supervisada (suele ser una entropía cruzada entre sus predicciones y los tokens de respuesta objetivo). Es el mismo entrenamiento que se utiliza en la mayoría de las tareas de machine learning supervisadas, que se aplica para especializar un LLM.

El SFT cambia el comportamiento, no el conocimiento. No enseña al modelo nuevos hechos o jerga que no haya visto en el entrenamiento previo. Enseña al modelo cómo responder, no qué saber. Si necesita nuevos conocimientos de dominio (como la terminología interna), utilice la generación aumentada por recuperación (RAG) para proporcionar ese contexto en el momento de la inferencia. A continuación, el SFT agrega el comportamiento de seguimiento de instrucciones deseado en la parte superior.

Funcionamiento

El SFT optimiza el LLM al minimizar la pérdida media de entropía cruzada en los tokens de respuesta, tratar los tokens de petición como contexto y ocultarlos de la pérdida. El modelo internaliza el estilo, la estructura y las reglas de decisión del objetivo, y aprende a generar la forma correcta de completar cada petición. Por ejemplo, para clasificar los documentos en categorías personalizadas, se refina el modelo con peticiones (el texto del documento) y terminaciones etiquetadas (las etiquetas de las categorías). Se entrena con esos pares hasta que el modelo muestre la etiqueta correcta para cada petición con una probabilidad alta.

Puede llevar a cabo el SFT con tan solo unos cientos de ejemplos y escalarlo hasta unos cientos de miles. Las muestras del SFT deben ser de alta calidad y estar directamente alineadas con el comportamiento deseado del modelo.

Cuándo usar el SFT

Utilice el SFT cuando tenga una tarea bien definida con las salidas deseadas claras. Si puede decir explícitamente “Con una entrada X, la salida correcta es Y” y puede recopilar ejemplos de este

tipo de asignaciones, el refinamiento supervisado es una buena opción. El SFT sobresale en los siguientes escenarios:

- Tareas de clasificación estructuradas o complejas: clasifique documentos internos o contratos en muchas categorías personalizadas. Con el SFT, el modelo aprende estas categorías específicas mejor que con peticiones por sí solas.
- Tareas de respuesta a preguntas o de transformación con respuestas conocidas: refine un modelo para que responda a preguntas de la base de conocimientos de una empresa o convierta datos de un formato a otro, en el que cada entrada tenga una respuesta correcta.
- Formato y estilo coherentes: entrene al modelo para que responda siempre en un formato o tono determinado mediante el refinamiento de los ejemplos del formato o tono correctos. Por ejemplo, si se entrena con pares de petición-respuesta que reflejan la voz de una marca concreta, se puede enseñar al modelo a generar salidas con ese estilo. El comportamiento de seguimiento de instrucciones suele enseñarse inicialmente mediante el SFT con ejemplos seleccionados que demuestran cómo debe comportarse un buen asistente.

El SFT es la forma más directa de enseñarle a un LLM una nueva habilidad o comportamiento cuando se puede especificar cuál es el comportamiento correcto. Utiliza la comprensión lingüística existente del modelo y la centra en la tarea. Utilice el SFT cuando desee que el modelo haga algo específico y tenga o pueda crear un conjunto de datos de ejemplos.

Utilice el SFT cuando pueda reunir pares de peticiones y respuestas de alta calidad que reflejen fielmente el comportamiento deseado. Encaja con tareas con objetivos claros o formatos deterministas, como esquemas, llamadas de funciones o herramientas y respuestas estructuradas en las que la imitación es una señal de entrenamiento adecuada. El objetivo es moldear el comportamiento: enseñar al modelo a tratar las peticiones como tareas, seguir instrucciones, adoptar políticas de tono y rechazo y producir un formato coherente. Planifique al menos cientos de demostraciones en las que la calidad, la coherencia y la deduplicación de datos sean más importantes que el volumen bruto. Para llevar a cabo una actualización sencilla y rentable, utilice métodos eficientes en cuanto a parámetros, como la adaptación de rango bajo, para entrenar adaptadores pequeños mientras deja intacta la mayor parte de la estructura básica.

Cuándo no utilizar el SFT

No utilice el SFT cuando la brecha se deba al conocimiento y no al comportamiento. No enseña al modelo nuevos hechos, jerga ni eventos recientes. En esos casos, utilice la generación aumentada por recuperación para llevar conocimiento externo a la inferencia. Evite el SFT cuando pueda

medir la calidad, pero no pueda etiquetar una sola respuesta correcta. Utilice el refinamiento por refuerzo con recompensas verificables o con un LLM como juez para optimizar esas recompensas directamente. Si sus necesidades o su contenido cambian con frecuencia, confíe en la recuperación y el uso de las herramientas en lugar de volver a entrenar el modelo.

Temas

- [SDK de Nova Forge](#)
- [Entrenamiento de los modelos de Amazon Nova](#)
- [Supervisión del progreso en las iteraciones](#)
- [Evaluación de su modelo entrenado por SageMaker AI](#)
- [Entrenamiento iterativo](#)

SDK de Nova Forge

El SDK de Nova Forge es un SDK para Python completo para personalizar los modelos de Amazon Nova. El SDK proporciona una interfaz unificada para el entrenamiento, la evaluación, la supervisión, la implementación y la inferencia de los modelos de Amazon Nova en diferentes plataformas, como SageMaker AI y Amazon Bedrock. Tanto si va a adaptar los modelos a tareas específicas de un dominio o a optimizar el rendimiento para su caso de uso, este SDK proporciona todo lo que necesita en una interfaz unificada.

Ventajas

- Un SDK para todo el ciclo de vida de la personalización del modelo, desde la preparación de los datos hasta la implementación y la supervisión.
- Compatibilidad con varios métodos de entrenamiento, como el entrenamiento previo continuo (CPT), el refinamiento supervisado (SFT), la optimización de preferencias directas (DPO) y el refinamiento por refuerzo (RFT), tanto de un solo turno como de varios turnos, con enfoques LoRA y de rango completo.
- Soporte integrado para Trabajos de entrenamiento de SageMaker, SageMaker HyperPod y Amazon Bedrock con administración automática de recursos.
- Ya no tendrá que buscar las fórmulas o el URI de contenedor correctos para sus técnicas de entrenamiento.
- Cree sus propias fórmulas de entrenamiento o use los valores predeterminados inteligentes del SDK con modificaciones de parámetros.

- El SDK compara la configuración con las combinaciones de modelos e instancias compatibles y valida los valores para evitar errores antes de que comience el entrenamiento.
- La supervisión integrada de Amazon CloudWatch le permite hacer un seguimiento del progreso del entrenamiento en tiempo real.
- MLflow integrado para hacer un seguimiento de los experimentos de entrenamiento con los servidores de seguimiento MLflow de SageMaker AI.

Requisitos

Versiones de Python compatibles

El SDK de Nova Forge se ha probado en:

- Python 3.12

Instalación

Para instalar este SDK, use el siguiente comando:

```
pip install amzn-nova-forge
```

Modelos y técnicas compatibles

El SDK admite los siguientes modelos y técnicas de la familia Amazon Nova:

Método	Modelos compatibles
Entrenamiento previo continuo	Todos los modelos de Nova (solo SMHP)
Refinamiento supervisado (LoRA)	Todos los modelos de Nova
Refinamiento supervisado (rango completo)	Todos los modelos de Nova (solo SMHP y SMTJ)
Optimización de preferencias directas (LoRA)	Modelos de Nova 1.0 (solo SMHP y SMTJ)
Optimización de preferencias directas (rango completo)	Modelos de Nova 1.0 (solo SMHP y SMTJ)

Método	Modelos compatibles
Refinamiento por refuerzo (LoRA)	Nova Lite 2.0
Refinamiento por refuerzo (rango completo)	Nova Lite 2.0 (solo SMHP y SMTJ)
Refinamiento por refuerzo de varios turnos (LoRA)	Nova Lite 2.0 (solo SMHP)
Refinamiento por refuerzo de varios turnos (rango completo)	Nova Lite 2.0 (solo SMHP)

Introducción

Temas

- [1. Preparación de datos](#)
- [2. Configuración de la infraestructura](#)
- [3. Entrenamiento](#)
- [4. Supervisión](#)
- [5. Evaluación](#)
- [6. Implementación](#)

1. Preparación de datos

Cargue el conjunto de datos desde su equipo o desde S3 y deje que el SDK se encargue de la transformación al formato correcto para el método de entrenamiento que haya elegido. También puede usar datos formateados y comenzar de inmediato.

```
from amzn_nova_forge.dataset.dataset_loader import JSONLDatasetLoader
from amzn_nova_forge.model.model_enums import Model, TrainingMethod, TransformMethod

loader = JSONLDatasetLoader()
loader.load("s3://your-bucket/training-data.jsonl")
loader.transform(
    method=TransformMethod.SCHEMA,
    training_method=TrainingMethod.SFT_LORA,
    model=Model.NOVA_LITE_2,
```

```
column_mappings={"question": "input", "answer": "output"},
)
```

2. Configuración de la infraestructura

Elija los recursos computacionales: el SDK valida las configuraciones y garantiza una configuración óptima.

```
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. Entrenamiento

Comience a entrenar con tan solo unas pocas líneas 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. Supervisión

Haga un seguimiento del progreso del entrenamiento directamente desde el 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. Evaluación

Evalúe el rendimiento del modelo usando varias [pruebas comparativas integradas](#) o diseñe sus propias evaluaciones.

```
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. Implementación

Implemente el modelo personalizado en producción gracias a la compatibilidad nativa con Amazon Bedrock o SageMaker.

```
from amzn_nova_forge.model.model_enums import DeployPlatform

# Bedrock provisioned throughput
deployment = customizer.deploy(
    model_artifact_path=result.model_artifacts.checkpoint_s3_path,
```

```
    deploy_platform=DeployPlatform.BEDROCK_PT,
    pt_units=10
)

# Bedrock On-Demand
deployment = customizer.deploy(
    model_artifact_path=result.model_artifacts.checkpoint_s3_path,
    deploy_platform=DeployPlatform.BEDROCK_OD,
    pt_units=10
)

# Sagemaker Real-time Inference
deployment = customizer.deploy(
    model_artifact_path=result.model_artifacts.checkpoint_s3_path,
    deploy_platform=DeployPlatform.SAGEMAKER,
    unit_count=10,
    sagemaker_instance_type="ml.p5.48xlarge",
    sagemaker_environment_variables={
        "CONTEXT_LENGTH": "12000",
        "MAX_CONCURRENCY": "16",
    }
)
```

Capacidades clave

Creación de fórmulas sobre la marcha

Gracias al SDK, no es necesario buscar las fórmulas o el URI de contenedor adecuados para técnicas específicas.

Procesamiento inteligente de datos

El SDK transforma automáticamente los datos en el formato correcto para el entrenamiento. Tanto si usa JSON, JSONL o CSV, el cargador de datos gestiona la conversión sin problemas. El cargador de datos admite texto y datos multimodales (imágenes y videos).

Soporte para infraestructura empresarial

El SDK funciona tanto con Trabajos de entrenamiento de SageMaker como con SageMaker HyperPod, y administra automáticamente los siguientes aspectos:

- Validación del tipo de instancia
- Validación de receta

- Validación del conjunto de datos
- Orquestación y supervisión de trabajos

El SDK también es compatible con Trabajo de entrenamiento de SageMaker sin servidor y con la personalización de Bedrock.

Evaluación completa

Evalúe sus modelos personalizados con [pruebas comparativas estándar](#) como las siguientes:

- Comprensión masiva del lenguaje multitarea (Massive Multitask Language Understanding, MMLU)
- Tareas de razonamiento avanzado (Advanced Reasoning Tasks, BBH)
- Preguntas y respuestas de posgrado diseñadas por Google (Graduate-Level Google-Proof Q&A, GPQA)

Use los valores predeterminados de las pruebas comparativas o modifíquelos para adaptarlos a sus necesidades:

- Traiga sus propias métricas (Bring Your Own Métrica, BYOM)
- Traiga su propio conjunto de datos (Bring Your Own Dataset, BYOD)

Implementación en entornos de producción

Implemente sus modelos en Amazon Bedrock o SageMaker AI con opciones para lo siguiente:

- Rendimiento aprovisionado de Bedrock: capacidad dedicada para garantizar un rendimiento uniforme.
- Bedrock bajo demanda (solo disponible para la personalización basada en LoRA): precios de pago por uso.
- Inferencia en tiempo real de SageMaker: capacidad dedicada para garantizar un rendimiento uniforme.

Inferencia en lotes

Lleve a cabo trabajos de inferencia a gran escala de manera eficiente:

- Procesamiento de miles de solicitudes en paralelo

- Agrupación automática de resultados
- Procesamiento por lotes rentable

Nova Forge

Los suscriptores de Nova Forge pueden usar el SDK para utilizar fórmulas de mezcla de datos.

Más información

¿Todo listo para empezar a personalizar los modelos de Nova con el SDK de Nova Forge? Consulte nuestro repositorio de GitHub para obtener guías detalladas, referencias de la API y más ejemplos:

<https://github.com/aws/nova-forge-sdk>

Entrenamiento de los modelos de Amazon Nova

El entrenamiento de los modelos de Amazon Nova en Trabajos de entrenamiento de SageMaker admite el refinamiento supervisado (SFT) y el refinamiento por refuerzo (RFT). Cada técnica responde a diferentes necesidades de personalización y se puede aplicar a distintas versiones de modelos de Amazon Nova.

Temas

- [Refinamiento de Nova 2.0](#)
- [Refinamiento por refuerzo \(RFT\) con modelos de Amazon Nova](#)

Refinamiento de Nova 2.0

Requisitos previos

Antes de empezar un trabajo de entrenamiento, tenga en cuenta lo siguiente.

- Buckets de Amazon S3 para almacenar sus datos de entrada y la salida de los trabajos de entrenamiento. Puede utilizar un bucket para ambos o buckets separados para cada tipo de datos. Asegúrese de que sus buckets estén en la misma región de AWS donde creó el resto de recursos para el entrenamiento. Para obtener más información, consulte [Creación de un bucket de uso general](#).
- Un rol de IAM con permisos para ejecutar un trabajo de entrenamiento. Asegúrese de asociar una política de IAM con `AmazonSageMakerFullAccess`. Para obtener más información, consulte [How to use SageMaker AI execution roles](#).

- Fórmulas básicas de Amazon Nova, consulte [???](#).

¿Qué es el SFT?

El refinamiento supervisado (SFT) entrena un modelo de lenguaje mediante pares de entrada y salida etiquetados. El modelo aprende a partir de ejemplos de demostración que consisten en peticiones y respuestas, y refina sus capacidades para alinearlas con tareas, instrucciones o comportamientos deseados específicos.

Preparación de datos

Descripción general

Los datos del SFT de Nova 2.0 utilizan el mismo formato de API de Converse que Nova 1.0, con la adición de campos de contenido de razonamiento opcionales. Para ver las especificaciones de formato completas, consulte:

- Contenido de razonamiento: [ReasoningContentBlock](#)
- Esquema de la API de Converse: [API de Converse](#)
- Restricciones del conjunto de datos: [Restricciones del conjunto de datos](#)

Características admitidas

- Tipos de entrada: texto, imagen o video en bloques de contenido del usuario
- Contenido del asistente: respuestas y contenido de razonamiento de solo texto
- Composición del conjunto de datos: debe ser homogéneo. Elija una de las siguientes opciones:
 - Turnos de solo texto
 - Turnos de texto e imagen
 - Turnos de texto y video (admite la comprensión de documentos)

Important

No se pueden mezclar imágenes y videos en el mismo conjunto de datos ni en turnos diferentes.

Limitaciones actuales

- Contenido de razonamiento multimodal: aunque el formato Converse admite contenido de razonamiento basado en imágenes, el SFT de Nova 2.0 solo admite contenido de razonamiento basado en texto en el campo `reasoningText`.
- Conjuntos de validación: no puede proporcionar ningún conjunto de datos de validación para el SFT con Nova 2.0. Si proporciona un conjunto de datos de validación, se ignorará durante el entrenamiento. Esta limitación se aplica tanto a envíos de trabajos basados en interfaz de usuario como programáticos.

Formatos multimedia compatibles

- Imágenes: PNG, JPEG, GIF
- Videos: MOV, MKV, MP4

Ejemplos de formato de datos

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"
}
```

Llamada a herramientas

El SFT de Nova 2.0 admite modelos de entrenamiento en patrones de uso de herramientas, lo que permite al modelo aprender cuándo y cómo debe invocar herramientas o funciones externas.

Formato de datos para llamadas a herramientas

Los datos de entrenamiento de llamada a herramientas incluyen una sección `toolConfig` que define las herramientas disponibles, junto con turnos de conversación que muestran los patrones de uso de las herramientas.

Ejemplo 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?"
    }
  ]
}
]
}
}

```

Requisitos de las llamadas a herramientas

Al crear los datos de entrenamiento de llamada a herramientas, siga estos requisitos:

Requisito	Descripción
Colocación de ToolUse	ToolUse solo debe aparecer en los turnos del asistente.
Colocación de ToolResult	ToolResult solo debe aparecer en los turnos del usuario.
Formato de ToolResult	ToolResult debe ser solo texto o JSON. Los modelos de Nova no admiten otras modalidades.
Formato de inputSchema	inputSchema en toolSpec debe ser un objeto de esquema JSON válido
Coincidencia de toolUseId	Cada ToolResult debe hacer referencia a un toolUseId válido de un ToolUse de asistente anterior, y cada toolUseId debe usarse exactamente una vez por conversación.

Notas importantes

- Asegúrese de que las definiciones de las herramientas sean coherentes en todos los ejemplos de entrenamiento.
- El modelo aprende los patrones de invocación de las herramientas a partir de las demostraciones que usted proporciona.
- Incluya varios ejemplos de cuándo se debe usar cada herramienta y cuándo no se deben usar herramientas.

Comprensión de documentos

El SFT de Nova 2.0 admite el entrenamiento en tareas basadas en documentos, lo que permite al modelo aprender a analizar y responder a preguntas sobre documentos PDF.

Formato de datos para la comprensión de documentos

Los datos de entrenamiento sobre la comprensión de documentos incluyen referencias a los documentos en los bloques de contenido del usuario. El modelo aprende a extraer y razonar sobre el contenido de documentos.

Ejemplo 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?"
    }
  ]
}
]
```

Limitaciones de la comprensión de documentos

Limitación	Details
Formato admitidos	Solo archivos PDF
Tamaño máximo del documento	10 MB
Mezcla de modalidades	Una muestra puede tener documentos y texto, pero no puede tener documentos mezclados con otras modalidades (imágenes, videos)

Prácticas recomendadas para la comprensión de documentos

- Asegúrese de que los documentos tengan un formato claro y que el texto sea extraíble.
- Proporcione varios ejemplos que abarquen diferentes tipos de documentos y formatos de preguntas.
- Incluya contenido de razonamiento para ayudar al modelo a aprender los patrones de análisis de documentos.

Comprensión de videos

El SFT de Nova 2.0 admite el entrenamiento en tareas basadas en videos, lo que permite al modelo aprender a analizar y responder a preguntas sobre contenido de videos.

Formato de datos para la comprensión de videos

Los datos de entrenamiento sobre la comprensión de videos incluyen referencias a los videos en los bloques de contenido del usuario. El modelo aprende a extraer información y razonar sobre el contenido de videos.

Ejemplo 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?"
    }
  ]
}
]
```

Limitaciones de la comprensión de video

Limitación	Details
Tamaño máximo del video	50 MB
Duración máxima del video	15 minutos
Videos por muestra	Solo se permite un video por muestra. No se admiten varios videos en la misma muestra.
Mezcla de modalidades	Una muestra puede tener video y texto, pero no puede tener videos combinados con otras modalidades (imágenes, documentos).

Formatos de video admitidos

- MOV
- MKV
- MP4

Prácticas recomendadas para la comprensión de videos

- Mantenga los videos concisos y centrados en el contenido relevante para la tarea.
- Asegúrese de que la calidad del video sea suficiente para que el modelo extraiga información significativa.
- Proporcione preguntas claras que hagan referencia a aspectos específicos del contenido de videos.
- Incluya varios ejemplos que abarquen diferentes tipos de videos y formatos de preguntas.

Modos de razonamiento y sin razonamiento

Descripción del contenido de razonamiento

El contenido de razonamiento (conocido también como cadena de pensamiento) captura los pasos de pensamiento intermedios del modelo antes de generar una respuesta final. En el turno del `assistant`, use el campo `reasoningContent` para incluir estos rastros de razonamiento.

¿Cómo se calcula la pérdida?

- Con contenido de razonamiento: la pérdida de entrenamiento incluye tanto los tokens de razonamiento como los de salida final.
- Sin contenido de razonamiento: la pérdida de entrenamiento se calcula solo en los tokens de salida final.

Puedes incluir `reasoningContent` en varios turnos del asistente en conversaciones de varios turnos.

Directrices de formato

- Use texto sin formato para contenido de razonamiento.

- Evite las etiquetas de marcado como `<thinking>` y `</thinking>` a menos que la tarea lo requiera específicamente.
- Asegúrese de que el contenido de razonamiento sea claro y relevante para el proceso de resolución de problemas.

¿Cuándo se debe habilitar el modo de razonamiento?

Establezca `reasoning_enabled: true` en la configuración de entrenamiento cuando:

- Los datos de entrenamiento tengan tokens de razonamiento.
- Quiera que el modelo genere tokens de pensamiento antes de producir las salidas finales.
- Necesite mejorar el rendimiento en tareas de razonamiento complejas.

Se permita entrenar a Nova con un conjunto de datos que no sea de razonamiento con `reasoning_enabled = true`. Sin embargo, hacerlo puede provocar que el modelo pierda sus capacidades de razonamiento, ya que Nova aprende principalmente a generar las respuestas presentadas en los datos sin aplicar el razonamiento. Si desea entrenar a Nova con un conjunto de datos sin razonamiento, pero aun así espera razonamiento durante la inferencia, puede deshabilitar el razonamiento durante el entrenamiento (`reasoning_enabled = false`), pero habilitarlo para la inferencia. Si bien este enfoque permite utilizar el razonamiento en el momento de la inferencia, no garantiza un rendimiento mejorado en comparación con la inferencia sin razonamiento. En general, habilite el razonamiento tanto para el entrenamiento como para la inferencia cuando utilice conjuntos de datos de razonamiento y desactívelo para ambos cuando utilice conjuntos de datos sin razonamiento.

Establezca `reasoning_enabled: false` cuando:

- Los datos de entrenamiento no tengan tokens de razonamiento.
- Entrene en tareas sencillas que no se beneficien de pasos de razonamiento explícitos.
- Quiera optimizar la velocidad y reducir el uso de tokens.

Generación de datos de razonamiento

Si el conjunto de datos carece de rastros de razonamiento, puede crearlos con un modelo con capacidad de razonamiento como Nova Premier. Proporcione los pares de entrada y salida al modelo y capture el proceso de razonamiento para crear un conjunto de datos con razonamiento aumentado.

Uso de tokens de razonamiento para el entrenamiento

Al entrenar con el modo de razonamiento habilitado, el modelo aprende a separar el razonamiento interno de la respuesta final. El proceso de entrenamiento:

- Organiza los datos en tríos: entrada, razonamiento y respuesta.
- Optimiza el uso de la pérdida de predicción estándar del siguiente token de los tokens de razonamiento y respuesta.
- Anima al modelo a razonar internamente antes de generar respuestas.

Contenido de razonamiento eficaz

El contenido de razonamiento de alta calidad debe incluir lo siguiente:

- Pensamientos y análisis intermedios
- Deducciones lógicas y pasos de inferencia
- Enfoques de resolución de problemas paso a paso
- Conexiones explícitas entre los pasos y las conclusiones

Esto ayuda al modelo a desarrollar la capacidad de “pensar antes de responder”.

Directrices de preparación de conjuntos de datos

Tamaño y calidad

- Tamaño recomendado: entre 2000 y 10 000 muestras
- Muestras mínimas: 200
- Prioridad: calidad por encima de cantidad. Asegúrese de que los ejemplos sean precisos y estén bien anotados.
- Alineación de las aplicaciones: el conjunto de datos debe reflejar de cerca los casos de uso de producción.

Diversidad

Incluya varios ejemplos que:

- Cubran la gama completa de entradas esperadas.

- Representen diferentes niveles de dificultad.
- Incluyan casos extremos y variantes.
- Eviten el sobreajuste a patrones estrechos.

Formato de salida

Especifique claramente el formato de salida deseado en las respuestas del asistente:

- estructuras JSON
- Tablas
- formato CSV
- Formatos personalizados específicos para la aplicación

Conversaciones de varios turnos

Para conjuntos de datos de varios turnos, recuerde lo siguiente:

- La pérdida se calcula solo en los turnos del asistente, no en los del usuario.
- Cada respuesta del asistente debe tener el formato correcto.
- Mantenga la coherencia en todos los turnos de la conversación.

Lista de comprobación de la calidad

- Tamaño del conjunto de datos suficiente (entre 2000 y 10 000 muestras)
- Varios ejemplos que cubren todos los casos de uso
- Formato de salida claro y coherente
- Etiquetas y anotaciones precisas
- Representación de escenarios de producción
- Sin contradicciones ni ambigüedades

Cargar los datos

Los conjuntos de datos deben cargarse en un bucket al que puedan acceder los trabajos de entrenamiento de SageMaker. Para obtener información sobre cómo establecer los permisos adecuados, consulte [Requisitos previos](#).

Inicio de un trabajo de entrenamiento

Selección de hiperparámetros y actualización de la fórmula

La configuración de Nova 2.0 es prácticamente la misma que la de Nova 1.0. Una vez que los datos de entrada se hayan cargado en S3, utilice la fórmula de la carpeta Refinamiento de [Fórmulas de SageMaker HyperPod](#). En el caso de Nova 2.0, a continuación se muestran algunos de los hiperparámetros clave que puede actualizar en función del caso de uso. A continuación se muestra un ejemplo de fórmula de PEFT del SFT de Nova 2.0. Para el URI de la imagen de contenedor, utilice `708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-TJ-SFT-V2-latest` para ejecutar un trabajo de refinamiento SFT.

Utilice la versión 2.254.1 del PySDK de SageMaker AI para garantizar una compatibilidad estricta con el entrenamiento de Nova. Si se actualiza el SDK a la versión 3.0, se producirán cambios importantes. La compatibilidad con la versión 3 del PySDK de SageMaker AI estará disponible próximamente.

Ejemplo 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

```

La fórmula también contiene prácticamente los mismos hiperparámetros que Nova 1.0. Los hiperparámetros más destacados son:

- **max_steps**: número de pasos para los que quiere ejecutar el trabajo. Por lo general, para una época (una ejecución de todo el conjunto de datos), el número de pasos es igual al número de muestras de datos dividido entre el tamaño del lote global. Cuanto mayor sea el número de pasos y menor sea el tamaño del lote global, más tardará en ejecutarse el trabajo.
- **reasoning_enabled**: controla el modo de razonamiento del conjunto de datos. Opciones:
 - **true**: habilita el modo de razonamiento (equivalente a un razonamiento alto).
 - **false**: deshabilita el modo de razonamiento.

Nota: En el caso del SFT, no existe ningún control detallado sobre los niveles de esfuerzo de razonamiento. Al configurar **reasoning_enabled: true**, se habilita una capacidad de razonamiento completa.

- `peft.peft_scheme`: al configurarlo como “lora”, se permite un refinamiento basado en PEFT. Al configurarlo en nulo (sin comillas), se habilita el refinamiento de rango completo.

Inicio del trabajo de entrenamiento

```
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

No se admite la transferencia de un conjunto de datos de validación para el refinamiento supervisado de Nova 2.0.

Para comenzar el trabajo:

- Actualice la fórmula con las rutas e hiperparámetros del conjunto de datos.
- Ejecute las celdas especificadas en el cuaderno para enviar el trabajo de entrenamiento.

El cuaderno gestiona el envío de trabajos y proporciona un seguimiento del estado.

Preparación de datos para el refinamiento multimodal

Las siguientes son directrices y requisitos para preparar los datos para el afinamiento de los modelos de comprensión:

1. El tamaño mínimo de los datos para el afinamiento depende de la tarea (es decir, si es compleja o sencilla), pero recomendamos que tenga al menos 100 muestras para cada tarea que desee que aprenda el modelo.
2. Recomendamos utilizar su petición optimizada en un entorno desde cero tanto durante el entrenamiento como durante la inferencia para lograr los mejores resultados.
3. Los conjuntos de datos de entrenamiento y validación deben ser archivos JSONL, donde cada línea sea un objeto JSON correspondiente a un registro. Estos nombres de archivo solo pueden estar compuestos por caracteres alfanuméricos, guiones bajos, guiones, barras y puntos.

4. Restricciones de imágenes y videos

- a. El conjunto de datos no puede contener diferentes modalidades multimedia. Es decir, el conjunto de datos puede ser texto con imágenes o texto con videos.
 - b. Una muestra (registro único en los mensajes) puede tener varias imágenes
 - c. Una muestra (registro único en los mensajes) solo puede tener un video
5. `schemaVersion` puede tener cualquier valor de cadena.
6. El turno `system` (opcional) puede ser una petición del sistema personalizada proporcionada por el cliente.
7. Los roles compatibles son `user` y `assistant`.
8. El primer turno en `messages` siempre debe comenzar con `"role": "user"`. El último turno es la respuesta del bot, que se denota con `"role": "assistant"`.
9. Amazon Bedrock debe poder acceder al `image.source.s3Location.uri` y al `video.source.s3Location.uri`.
- 10 Su rol de servicio de Amazon Bedrock debe poder acceder a los archivos de imágenes en Amazon S3. Para obtener más información sobre la concesión de acceso, consulte [Creación de un rol de servicio para la personalización de modelos](#).
- 11 Las imágenes o videos deben estar en el mismo bucket de Amazon S3 que su conjunto de datos. Por ejemplo, si su conjunto de datos está en `s3://amzn-s3-demo-bucket/train/train.jsonl`, entonces sus imágenes o videos deben estar en `s3://amzn-s3-demo-bucket`
- 12 Los términos `User:`, `Bot:`, `Assistant:`, `System:`, `<image>`, `<video>` y `[EOS]` son palabras clave reservadas. Si una petición del usuario o del sistema comienza con alguna de estas palabras clave, o las tiene en las peticiones, el trabajo de entrenamiento fallará debido a problemas de datos. Si necesita usar estas palabras clave para su caso de uso, debe sustituirlas por una palabra clave diferente con un significado similar para que su entrenamiento pueda continuar.

Note

Para validar el conjunto de datos antes de enviar un trabajo de refinamiento, puede usar el [script de validación del conjunto de datos](#) disponible en GitHub.

Temas

- [Ejemplo de formatos de conjuntos de datos](#)

- [Restricciones del conjunto de datos](#)

Ejemplo de formatos de conjuntos de datos

Los siguientes ejemplos de formatos de conjuntos de datos proporcionan una guía que puede seguir.

Formato de afinamiento personalizado solo de texto

El siguiente ejemplo es para el afinamiento personalizado solo de texto.

```
// train.jsonl
{
  "schemaVersion": "bedrock-conversation-2024",
  "system": [
    {
      "text": "You are a digital assistant with a friendly personality"
    }
  ],
  "messages": [
    {
      "role": "user",
      "content": [
        {
          "text": "What is the capital of Mars?"
        }
      ]
    },
    {
      "role": "assistant",
      "content": [
        {
          "text": "Mars does not have a capital. Perhaps it will one day."
        }
      ]
    }
  ]
}
```

Formato de afinamiento personalizado de una sola imagen

El siguiente ejemplo es para el afinamiento personalizado de texto y una sola imagen.

```
// train.jsonl{
```

```

"schemaVersion": "bedrock-conversation-2024",
"system": [{
  "text": "You are a smart assistant that answers questions respectfully"
}],
"messages": [{
  "role": "user",
  "content": [{
    "text": "What does the text in this image say?"
  },
  {
    "image": {
      "format": "png",
      "source": {
        "s3Location": {
          "uri": "s3://your-bucket/your-path/your-image.png",
          "bucketOwner": "your-aws-account-id"
        }
      }
    }
  }
]}],
{
  "role": "assistant",
  "content": [{
    "text": "The text in the attached image says 'LOL'."
  }]
}]
}

```

Formato de afinamiento personalizado de video

El siguiente ejemplo es para el afinamiento personalizado de texto y video.

```

{
  "schemaVersion": "bedrock-conversation-2024",
  "system": [{
    "text": "You are a helpful assistant designed to answer questions crisply and to the point"
  }],
  "messages": [{
    "role": "user",
    "content": [{

```



```

        "text": "How many white items are visible in this video?"
    },
    {
        "video": {
            "format": "mp4",
            "source": {
                "s3Location": {
                    "uri": "s3://your-bucket/your-path/your-video.mp4",
                    "bucketOwner": "your-aws-account-id"
                }
            }
        }
    }
],
{
    "role": "assistant",
    "content": [{
        "text": "There are at least eight visible items that are white"
    }]
}
]
}

```

Restricciones del conjunto de datos

Amazon Nova aplica las siguientes restricciones a las personalizaciones de modelos para los modelos de comprensión.

Modelo	Muestras mínimas	Muestras máximas	Longitud del contenido
Nova 2 Lite	8	20 000	32 000

Restricciones de imágenes y videos

Número máximo de imágenes	10/muestra
Tamaño máximo de archivo de imagen	10 MB
Número máximo de videos	1/muestra

Duración máxima del video	90 segundos
Tamaño máximo de archivo de video	50 MB

Formatos multimedia compatibles

- Imagen: png, jpeg, gif, webp
- Video: mov, mkv, mp4, webm

Refinamiento por refuerzo (RFT) con modelos de Amazon Nova

Descripción general

¿Qué es el RFT?

El refinamiento por refuerzo (RFT) mejora el rendimiento del modelo al entrenarlo con señales de comentarios (puntuaciones medibles o recompensas que indican el rendimiento del modelo) en lugar de con respuestas exactas correctas. A diferencia del refinamiento supervisado, que aprende de los pares de entradas y salidas, el RFT utiliza funciones de recompensas para evaluar las respuestas del modelo y lo optimiza de forma iterativa para maximizar estas recompensas. Este enfoque destaca al definir el resultado exacto correcto, pero le permite medir de forma fiable la calidad de la respuesta.

Cuándo se debe usar el RFT

Utilice el RFT cuando pueda definir criterios de éxito claros y medibles, pero tenga dificultades para proporcionar resultados exactos y correctos para el entrenamiento. Es ideal para:

- Tareas en las que la calidad es subjetiva o multifacética (escritura creativa, optimización del código, razonamiento complejo)
- Escenarios con múltiples soluciones válidas en los que algunas son claramente mejores que otras
- Aplicaciones que requieran mejoras iterativas, personalización o el cumplimiento de reglas empresariales complejas
- Casos en los que recopilar ejemplos etiquetados de alta calidad es caro o poco práctico

Los mejores casos de uso

El RFT sobresale en dominios en los que la calidad de los resultados se puede medir objetivamente, pero las respuestas óptimas son difíciles de definir por adelantado:

- Resolución de problemas matemáticos y generación de código
- Razonamiento científico y análisis de datos estructurados
- Tareas que requieren razonamiento paso a paso o resolución de problemas de varios turnos
- Aplicaciones que equilibran varios objetivos (precisión, eficiencia, estilo)
- Escenarios en los que el éxito se puede verificar mediante programación con resultados de ejecución o métricas de rendimiento

Modelos compatibles

Nova Lite 2.0

Información general sobre el formato de datos

Los datos de entrenamiento RFT deben seguir el [formato](#) de refinamiento por refuerzo de OpenAI. Cada ejemplo de entrenamiento es un objeto JSON que contiene lo siguiente:

- Una matriz `messages` con turnos conversacionales con los roles `system` y `user`
- Un campo `reference_answer` que contiene el resultado esperado o los criterios de evaluación para el cálculo de recompensas

Limitaciones actuales

- Solo texto

Ejemplos de formato de datos

Cada ejemplo debe estar en una sola línea del archivo JSONL, con un objeto JSON por línea.

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
  }
}

```

El campo `reference_answer` contiene el resultado esperado o los criterios de evaluación que la función de recompensa utiliza para puntuar la respuesta del modelo. No se limita a resultados estructurados, sino que puede contener cualquier formato que ayude a la función de recompensas a evaluar la calidad.

Recomendaciones de tamaño de conjunto de datos

Punto de partida

- Mínimo 100 ejemplos de entrenamiento
- Mínimo 100 ejemplos de evaluación

Enfoque de priorización de la evaluación

Antes de invertir en un entrenamiento RFT a gran escala, evalúe el rendimiento de línea de base del modelo:

- Alto rendimiento (recompensa superior al 95 %): el RFT puede no ser necesario, el modelo ya funciona bien.
- Rendimiento muy bajo (recompensa del 0 %): cambie primero al SFT para establecer las capacidades básicas.
- Rendimiento moderado: es probable que el RFT sea adecuado.

Comenzar con un conjunto de datos pequeño le permite:

- Validar que la función de recompensas no contenga errores
- Confirmar que el RFT sea el enfoque adecuado para su caso de uso
- Identificar y solucionar problemas con antelación
- Probar el flujo de trabajo antes de escalar verticalmente

Una vez validado, puede ampliarlo a conjuntos de datos más grandes para mejorar aún más el rendimiento.

Características de los datos de entrenamiento eficaces

Claridad y coherencia

Los buenos ejemplos del RFT requieren datos de entrada claros e inequívocos que permitan un cálculo preciso de las recompensas en las diferentes salidas del modelo. Evite el ruido en los datos, lo que incluye lo siguiente:

- Formato incoherente
- Etiquetas o instrucciones contradictorias
- Peticiones ambiguas
- Conflictos en las respuestas de referencia

Cualquier ambigüedad inducirá a error durante el proceso de entrenamiento y provocará que el modelo aprenda comportamientos no deseados.

Diversidad

El conjunto de datos debe capturar toda la diversidad de casos de uso de producción para garantizar un rendimiento real sólido. Incluya:

- Diferentes formatos de entrada y casos extremos
- Asignación de patrones reales de uso de producción a partir de registros y análisis de usuarios
- Muestras de distintos tipos de usuarios, regiones geográficas y variaciones estacionales
- Inclusión de niveles de dificultad, desde problemas simples hasta problemas complejos

Consideraciones sobre la función de recompensas

Diseñe la función de recompensas para un entrenamiento eficiente:

- Ejecución en segundos (no minutos)
- Paralelización eficaz con Lambda
- Devolución de puntuaciones coherentes y fiables
- Gestión de diferentes tipos de salidas del modelo sin problemas

Las funciones de recompensas rápidas y escalables permiten una iteración rápida y una experimentación rentable.

Propiedades adicionales

El formato de datos del RFT admite campos personalizados que van más allá de los requisitos básicos del esquema (`messages` y `reference_answer`). Esta flexibilidad le permite agregar cualquier dato adicional que su función de recompensas necesite para una evaluación adecuada.

Note

No tiene que configurarlo en su fórmula: el formato de datos admite campos adicionales de forma inherente. Solo tiene que incluirlos en el JSON de los datos de entrenamiento para que se transfieran a la de recompensas en el campo `metadata`.

Propiedades adicionales comunes

Campos de metadatos de ejemplo:

- `task_id`: identificador único de seguimiento

- `difficulty_level`: indicador de la complejidad del problema
- `domain`: categoría o área del asunto
- `expected_reasoning_steps`: número de pasos de la solución

Ejemplo con propiedades adicionales

```
{
  "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
}
```

Estos campos adicionales se transfieren a la función de recompensas durante la evaluación, lo que permite aplicar una lógica de puntuación sofisticada adaptada a su caso de uso específico.

Configuración de entrenamiento

Fórmula de muestra

```
# 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)

```

Entrenamiento RFT con LLM como juez

Descripción general

Los modelos de lenguaje de gran tamaño (LLM) se utilizan cada vez más como jueces en los flujos de trabajo de refinamiento por refuerzo (RFT), ya que proporcionan señales de recompensas automatizadas que guían la optimización de los modelos. Con este enfoque, el LLM evalúa las salidas del modelo en función de criterios específicos (ya sea la corrección, la calidad, la adherencia al estilo o la equivalencia semántica) y asigna recompensas que impulsan el proceso de aprendizaje por refuerzo.

Esto es particularmente valioso para tareas en las que las funciones de recompensas tradicionales son difíciles de definir mediante programación, como determinar si diferentes representaciones (como “1/3”, “0,333” y “un tercio”) son semánticamente equivalentes, o evaluar cualidades matizadas como la coherencia y la relevancia. Al utilizar jueces basados en LLM como funciones de recompensas, puede escalar el RFT a dominios complejos sin necesidad de una amplia anotación humana, lo que permite una iteración rápida y una mejora continua de los modelos en varios casos de uso, más allá de los problemas de alineación tradicionales.

Selección del modo de razonamiento

Modos disponibles

- ninguno: sin razonamiento (omite el campo `reasoning_effort`)

- bajo: sobrecarga de razonamiento mínima
- alto: capacidad de razonamiento máxima (opción predeterminada cuando se especifica `reasoning_effort`)

 Note

No hay una opción media para el RFT. Si el campo `reasoning_effort` no está en la configuración, el razonamiento está desactivado. Cuando el razonamiento está habilitado, debe configurar `max_new_tokens` en 32 768 para dar cabida a las salidas de razonamiento extendido.

Cuándo se debe usar cada modo

Utilice el razonamiento alto para:

- Tareas analíticas complejas
- Resolución de problemas matemáticos
- Deducción lógica de varios pasos
- Tareas en las que pensar paso a paso agrega valor

Utilice ninguno (omite `reasoning_effort`) o un razonamiento bajo para:

- Consultas de hechos sencillas
- Clasificaciones directas
- Optimización de velocidad y costo
- Preguntas y respuestas directas

Compensaciones de costo y rendimiento

Los modos de razonamiento alto aumentan lo siguiente:

- Tiempo y costo del entrenamiento
- Latencia y costo de la inferencia
- Capacidad del modelo para tareas de razonamiento complejas

Validación del juez de LLM

Antes de implementar un LLM como juez en producción, compruebe que las evaluaciones del modelo del juez se ajusten al juicio humano. Esto implica:

- Medir las tasas de acuerdo entre el juez de LLM y los evaluadores humanos sobre muestras representativas de la tarea
- Garantizar que el acuerdo del LLM con las personas cumpla o supere las tasas de acuerdo interhumano
- Identificar posibles sesgos en el modelo del juez
- Crear la confianza de que la señal de recompensas guíe al modelo en la dirección deseada

Este paso de validación ayuda a garantizar que el proceso de evaluación automatizada produzca modelos que cumplan con los criterios de calidad de producción.

Configuración de Lambda para juez de LLM

El uso de un LLM como juez es una extensión del uso de las funciones de Lambda para el aprendizaje por refuerzo con recompensas verificables (RLVR). Dentro de la función de Lambda, puede hacer una llamada a uno de los modelos alojados en Amazon Bedrock.

Requisitos de configuración importantes:

Configuración	Requisito	Details
Rendimiento de Amazon Bedrock	Cuota suficiente	Asegúrese de que la cuota de rendimiento para el modelo de Amazon Bedrock utilizado sea suficiente para la carga de trabajo de entrenamiento.
Tiempo de espera de Lambda	Tiempo de espera ampliado	Configure el tiempo de espera de la función de Lambda en hasta un máximo de 15 minutos. La configuración predeterminada es de 3 segundos, lo que no es suficiente para las respuestas del modelo de Amazon Bedrock.
Simultaneidad de Lambda	Mayor simultaneidad	La función de Lambda se invoca en paralelo durante el entrenamiento. Aumente la

Configuración	Requisito	Details
		simultaneidad para maximizar el rendimiento disponible.
Configuración de fórmulas	Coincidencia de la configuración de Lambda	El límite de simultaneidad debe estar configurado en la fórmula.

Creación y ejecución de trabajos

Inicio de un trabajo de entrenamiento

Utilice la plantilla de cuaderno de trabajos de entrenamiento de SageMaker: <https://docs.aws.amazon.com/sagemaker/latest/dg/nova-fine-tuning-training-job.html#nova-model-training-jobs-notebook>.

Requisitos de instancias

El contenedor admite tanto el entrenamiento de rango completo como el de LoRA:

- Entrenamiento de LoRA: 2/4/6/8 × instancias p5.48xlarge o p5en.48xlarge
- Entrenamiento de rango completo: 2/4/6/8 × instancias p5.48xlarge (obligatorias)

Supervisión del entrenamiento

Los registros de entrenamiento incluyen métricas completas en cada paso. Categorías de métricas clave:

Métricas de recompensas

- `critic/rewards/mean`, `critic/rewards/max`, `critic/rewards/min`: distribución de recompensas
- `val-score/rewards/mean@1`: recompensas de validación

Comportamiento del modelo

- `actor/entropy`: variación de la política (mayor = más exploratoria)

Estado del entrenamiento

- actor/pg_loss: pérdida de gradiente de la política
- actor/pg_clipfrac: frecuencia de las actualizaciones recortadas
- actor/grad_norm: magnitud del gradiente

Características de la respuesta

- prompt_length/mean, prompt_length/max, prompt_length/min: estadísticas del token de entrada
- response_length/mean, response_length/max, response_length/min: estadísticas del token de salida
- response/aborted_ratio: porcentaje de generación incompleta (0 = todo completado)

Desempeño

- perf/throughput: rendimiento del entrenamiento
- perf/time_per_step: tiempo por paso del entrenamiento
- timing_per_token_ms/*: tiempo de procesamiento por token

Uso de recursos

- perf/max_memory_allocated_gb, perf/max_memory_reserved_gb: memoria de la GPU
- perf/cpu_memory_used_gb: memoria de la CPU

Uso de modelos de ajuste fino

Después de finalizar el entrenamiento, el punto de control final del modelo se guarda en la ubicación de salida especificada. La ruta del punto de control está disponible en:

- Registros de entrenamiento
- Archivo `manifest.json` en la ubicación de salida de Amazon S3 (definida por `output_s3_uri` en el cuaderno)

Limitaciones y prácticas recomendadas

Limitaciones

- Tiempo de espera de Lambda: las funciones de recompensas deben completarse en 15 minutos (evita procesos fuera de control y administra los costos).
- Solo turno único: no se admiten conversaciones de varios turnos.
- Requisitos de datos: necesita una diversidad suficiente, ya que tiene dificultades para obtener recompensas escasas (menos del 5 % de ejemplos positivos).
- Costo computacional: es más caro que el refinamiento supervisado.
- Sin datos multimodales: solo se admite el tipo de datos de texto.

Prácticas recomendadas

Empezar poco a poco

- Comience con entre 100 y 200 ejemplos.
- Valide la corrección de la función de recompensas.
- Escale de forma gradual en función de los resultados.

Evaluación del entrenamiento previo

- Pruebe el rendimiento del modelo de línea de base antes del RFT.
- Si las recompensas son del 0 % de forma constante, utilice antes el SFT para establecer las capacidades básicas
- Si las recompensas son superiores al 95 %, es posible que el RFT no sea necesario.

Supervisión del entrenamiento

- Haga un seguimiento del promedio de las puntuaciones y la distribución de las recompensas
- Observe si hay sobreajuste (aumento de recompensas de entrenamiento con disminución de recompensas de validación).
- Busque patrones preocupantes:
 - Recompensas que se estancan por debajo de 0,15
 - Aumento de la variación de las recompensas a lo largo del tiempo

- Reducción del rendimiento de validación

Optimización de las funciones de recompensas

- Ejecución en segundos (no minutos)
- Minimice las llamadas a la API externa.
- Use algoritmos eficientes.
- Implemente una gestión de errores adecuada.
- Aproveche el escalado paralelo de Lambda.

Estrategia de iteración

Si las recompensas no mejoran:

- Ajuste el diseño de la función de recompensas.
- Aumente la diversidad de los conjuntos de datos.
- Agregue más ejemplos representativos.
- Verifique que las señales de recompensas sean claras y coherentes.

Capacidades avanzadas: Nova Forge

Para los usuarios que requieren capacidades avanzadas más allá de las limitaciones del RFT estándar, Nova Forge está disponible como un servicio de suscripción de pago que ofrece:

- Soporte para conversación de varios turnos
- Funciones de recompensas con un tiempo de ejecución superior a 15 minutos
- Algoritmos y opciones de ajuste adicionales
- Modificaciones de fórmulas de entrenamiento personalizadas
- Técnicas de IA de vanguardia

Nova Forge se ejecuta en SageMaker HyperPod y se ha diseñado para ayudar a los clientes empresariales a crear sus propios modelos de frontera.

Comandos y consejos útiles

Hay disponible una colección de [scripts de observabilidad](#) para ayudar a supervisar el estado y el progreso de los trabajos de entrenamiento.

Los scripts disponibles le permiten:

- Habilitar las notificaciones de correo electrónico para actualizar el estado de los trabajos de entrenamiento
- Obtener estimaciones del tiempo de entrenamiento en función de las configuraciones de los trabajos
- Obtener aproximaciones del tiempo que se espera que dure el entrenamiento para los trabajos en curso

Instalación

Note

Asegúrese de actualizar las credenciales de AWS antes de utilizar cualquiera de los siguientes scripts.

```
pip install boto3
git clone https://github.com/aws-samples/amazon-nova-samples.git
cd amazon-nova-samples/customization/SageMakerUilts/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 [en esta página](#) los detalles y ejemplos adicionales.



Supervisión del progreso en las iteraciones

Puede hacer un seguimiento de las métricas a través de MLflow.

Personalización de Nova: configuración de MLflow para SageMaker HyperPod

Para permitir que el entorno de SageMaker HyperPod envíe métricas a MLflow, es necesario realizar una configuración adicional.

1. Abra Amazon SageMaker AI.
2. Seleccione SageMaker Studio.
 - a. Si ya hay un perfil creado, seleccione Abrir Studio.
 - b. Si no hay ningún perfil creado, seleccione Crear un dominio de SageMaker para configurar uno.
3. Seleccione MLflow. Si no hay ninguna aplicación MLflow creada, seleccione Crear aplicación de MLflow.
4. Haga clic en el botón de copiar/pegar o en el elemento del menú Ver detalle de la aplicación MLflow para obtener el ARN. Lo necesitará cuando envíe su trabajo de entrenamiento.



5. En el rol de puesta en marcha del clúster de HyperPod, agregue la siguiente política. Esto permitirá que el clúster de HyperPod llame a la API de 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": "*"
    }
  ]
}
```

Envío de un trabajo a través de la CLI

Especifique 4 nuevos parámetros de anulación, ya sea en la línea de comandos o en la fórmula yaml.

1. `mlflow_tracking_uri`: el ARN de la aplicación MLflow
2. `mlflow_experiment_name`: el nombre de la característica de este experimento.
3. `mlflow_experiment_name`: el nombre del experimento en el que se almacenarán las métricas en MLflow.
4. `mlflow_run_name`: el nombre de este experimento.

Línea de comandos

```
--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"
```

Envío de un trabajo a través de la interfaz de usuario de SageMaker Studio

La integración de MLflow ya forma parte de la experiencia de la interfaz de usuario de SageMaker Studio. Al enviar un trabajo de entrenamiento, simplemente indique qué instancia de la aplicación MLFlow va a utilizar.

1. En SageMaker Studio, vaya a Modelos > Nova 2.0 Lite > Personalizar > Personalizar con interfaz de usuario.
2. Amplíe la sección Configuración avanzada.
3. Seleccione la aplicación MLflow a la que desee enviar las métricas de entrenamiento. También puede indicar el nombre del experimento y configurar su puesta en marcha aquí.



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

Envío de un trabajo a través de la AWS CLI

Si utiliza la AWS CLI, debe crear una aplicación MLflow y pasarla como entrada a la solicitud de la API del trabajo de entrenamiento.

```
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)
```

Creación de una aplicación MLflow

Uso de la interfaz de usuario de Studio: si crea un trabajo de entrenamiento a través de la interfaz de usuario de Studio, se crea automáticamente una aplicación MLflow predeterminada que se selecciona por defecto en Opciones avanzadas.

Uso de la CLI: si usa la CLI, debe crear una aplicación MLflow y pasarla como entrada a la solicitud de la API del trabajo de entrenamiento.

```
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)
```

Acceso a la aplicación MLflow

Uso de la CLI: cree una URL prefirmada para acceder a la interfaz de usuario de la aplicación MLflow:

```
aws sagemaker create-presigned-mlflow-app-url \
```

```
--arn $mlflow_app_arn \  
--region $region \  
--output text
```

Uso de la interfaz de usuario de Studio: la interfaz de usuario de Studio muestra las métricas clave almacenadas en MLflow y proporciona un enlace a la interfaz de usuario de la aplicación MLflow.

Métricas clave para hacer un seguimiento

Supervise estas métricas en las iteraciones para evaluar la mejora y hacer un seguimiento del progreso del trabajo:

Para SFT

- Curvas de pérdidas de entrenamiento
- Número de muestras consumidas y tiempo de procesamiento
- Precisión del rendimiento en conjuntos de prueba reservados
- Cumplimiento del formato (por ejemplo, velocidad de salida JSON válida)
- Perplejidad en datos de evaluación específicos del dominio

Para RFT

- Puntuaciones promedio de recompensa durante el entrenamiento
- Distribución de las recompensas (porcentaje de respuestas con alta recompensa)
- Tendencias de la recompensa en validación (atención al sobreajuste)
- Tasas de éxito específicas por tarea (por ejemplo, tasa de aprobación en procesamiento de código, precisión en problemas matemáticos)

General

- Diferencias de rendimiento en pruebas comparativas entre iteraciones
- Puntuaciones de evaluación humana en muestras representativas
- Métricas de producción (si se realiza una implementación iterativa)

Cómo determinar cuándo parar

Deje de iterar en los siguientes casos:

- Rendimiento estancado: el entrenamiento adicional ya no mejora significativamente las métricas objetivo
- Cambio de técnica para seguir progresando: si una técnica se estanca, pruebe a cambiarla (p. ej., SFT → RFT → SFT) para superar los límites de rendimiento
- Métricas objetivo alcanzadas: se cumplen sus criterios de rendimiento correcto.
- Regresión detectada: las nuevas iteraciones reducen el rendimiento (consulte los procedimientos de reversión que aparecen a continuación)

Para obtener información detallada sobre los procedimientos de evaluación, consulte la sección Evaluación.

Evaluación de su modelo entrenado por SageMaker AI

El objetivo del proceso de evaluación es evaluar el rendimiento del modelo entrenado comparándolo con referencias o un conjunto de datos personalizado. El proceso de evaluación suele incluir pasos para crear una fórmula de evaluación basada en el modelo entrenado, especificar los conjuntos de datos y las métricas de la evaluación, enviar un trabajo independiente para la evaluación y evaluar en función de referencias estándar o datos personalizados. El proceso de evaluación devolverá métricas de rendimiento almacenadas en su bucket de Amazon S3.

Note

El proceso de evaluación que se describe en este tema es un proceso sin conexión. El modelo se prueba con referencias fijas con respuestas predefinidas, en lugar de evaluarse en tiempo real o mediante interacciones con los usuarios en directo. Para evaluaciones en tiempo real, puede probar el modelo después de implementarlo en Amazon Bedrock llamando a las API de tiempo de ejecución de [Amazon Bedrock](#).

Temas

- [Requisitos previos](#)
- [Tareas de referencia disponibles](#)
- [Configuraciones específicas de la evaluación](#)
- [Ejecución de trabajos de entrenamiento de evaluación](#)
- [Evaluación y análisis de los resultados de la evaluación](#)
- [Prácticas recomendadas y solución de problemas de evaluación](#)

- [Subtareas disponibles](#)
- [Evaluación del modelo de razonamiento](#)
- [Evaluación del RFT](#)
- [Implementación de funciones de recompensas](#)

Requisitos previos

Antes de empezar un trabajo de entrenamiento de evaluación, tenga en cuenta lo siguiente.

- Un modelo de Amazon Nova entrenado por SageMaker AI del que desee evaluar su rendimiento.
- Fórmula básica de Amazon Nova para evaluación. Para obtener más información, consulte [???](#).

Tareas de referencia disponibles

Hay un paquete de códigos de ejemplo que muestra cómo calcular métricas de referencia mediante la característica de evaluación de modelos de SageMaker AI para Amazon Nova. Para acceder a los paquetes de códigos, consulte [sample-Nova-lighteval-custom-task](#).

A continuación se muestra una lista de las referencias estándar del sector disponibles y compatibles. Puede especificar las siguientes referencias para el parámetro `eval_task`.

Referencia disponibles para la evaluación del modelo

Referencia	Modalidad	Descripción	Métricas	Strategy (Estrategia)	Subtarea disponible
mmlu	Texto	Comprensión del lenguaje multitarea: evalúa los conocimientos sobre 57 materias.	precisión	zs_cot	Sí
mmlu_pro	Texto	MMLU (subconjunto profesional)	precisión	zs_cot	No

Referencia	Modalidad	Descripción	Métricas	Strategy (Estrategia)	Subtarea disponible
		al): se centra en dominios profesionales como derecho, medicina, contabilidad e ingeniería.			
bbh	Texto	Tareas de razonamiento avanzado: conjunto de problemas complejos que ponen a prueba las habilidades cognitivas y de resolución de problemas de nivel superior.	precisión	fs_cot	Sí

Referencia	Modalidad	Descripción	Métricas	Strategy (Estrategia)	Subtarea disponible
gpqa	Texto	Respuesta a preguntas de física general: evalúa la comprensión de conceptos de física y habilidades relacionadas con la resolución de problemas.	precisión	zs_cot	No
math	Texto	Resolución de problemas matemáticos: mide el razonamiento matemático en temas como álgebra, cálculo y problemas verbales.	exact_match	zs_cot	Sí

Referencia	Modalidad	Descripción	Métricas	Strategy (Estrategia)	Subtarea disponible
strong_reject	Texto	Tarea de control de calidad: prueba la capacidad del modelo para detectar y rechazar contenido inapropiado, dañino o incorrecto.	desviación	zs	Sí
ifeval	Texto	Evaluación de seguimiento de instrucciones: mide la precisión con la que un modelo sigue las instrucciones dadas y completa las tareas según las especificaciones.	precisión	zs	No

Referencia	Modalidad	Descripción	Métricas	Strategy (Estrategia)	Subtarea disponible
gen_qa	Multimodal (imagen)	Evaluación personalizada de conjuntos de datos: permite usar un conjunto de datos propio para realizar pruebas comparativas y así comparar resultados del modelo con respuestas de referencia con métricas como ROUGE y BLEU. gen_qa admite la inferencia de imágenes para los modelos basados en Amazon Nova L o Amazon Nova F	all	gen_qa	No

Referencia	Modalidad	Descripción	Métricas	Strategy (Estrategia)	Subtarea disponible
		También es compatible con funciones de Lambda que usen sus propias métricas. (En el caso de la evaluación de RFT, utilice la fórmula de evaluación de RFT)			
mmmu	Multimodal	Comprensión multidisciplinaria masiva y multimodal (MMMU): prueba comparativa de nivel universitario que consta de preguntas de opción múltiple y preguntas abiertas de 30 disciplinas.	precisión	zs_cot	Sí

Referencia	Modalidad	Descripción	Métricas	Strategy (Estrategia)	Subtarea disponible
llm_judge	Texto	Comparación de preferencias de LLM como juez: utiliza un modelo Nova Judge para determinar la preferencia entre las respuestas emparejadas (B en comparación con A) para las peticiones, calculando la probabilidad de que se prefiera B a A.	all	judge	No

Referencia	Modalidad	Descripción	Métricas	Strategy (Estrategia)	Subtarea disponible
mm_llm_judge	Multimodal (imagen)	Esta nueva prueba comparativa se comporta igual que la indicada anteriormente, llm_judge , la cual está basada en texto. La única diferencia es que admite la inferencia de imágenes.	all	judge	No

Referencia	Modalidad	Descripción	Métricas	Strategy (Estrategia)	Subtarea disponible
rubric_llm_judge	Texto	Rubric Judge es un modelo de evaluación mejorado de LLM como juez basado en Nova 2.0 Lite. A diferencia del modelo juez original , que solo proporciona veredictos preferenciales, Rubric Judge genera de forma dinámica criterios de evaluación personalizados adaptados a cada petición y puntúa de forma detallada varias dimensiones.	all	judge	No

Referencia	Modalidad	Descripción	Métricas	Strategy (Estrategia)	Subtarea disponible
aime_2024	Texto	AIME 2024: problemas del American Invitational Mathematics Examination (AIME) que ponen a prueba el razonamiento matemático avanzado y la resolución de problemas	exact_match	zs_cot	No
calendar_scheduling	Texto	Natural Plan: tarea de planificación de calendario que ponen a prueba las capacidades de planificación para programar reuniones a lo largo de varios días y con múltiples personas	exact_match	fs	No

Referencia	Modalidad	Descripción	Métricas	Strategy (Estrategia)	Subtarea disponible
humaneval	Texto	HumanEval : conjunto de datos de referencia diseñado para evaluar las capacidades de generación de código de modelos de lenguaje de gran tamaño	pass@1	zs	No

Configuraciones específicas de la evaluación

A continuación, encontrará un desglose de los componentes clave de la fórmula y una guía sobre cómo modificarlos para sus casos de uso.

Comprensión y modificación de sus fórmulas

Configuración general de ejecución

```
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: nombre descriptivo del trabajo de evaluación.

- `model_type`: especifica la variante del modelo Nova que desea utilizar. No modifique manualmente este campo. Las opciones son:
 - `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`: ruta al modelo base o ruta de s3 para el punto de comprobación entrenado posteriormente. Las opciones son:
 - `nova-micro/prod`
 - `nova-lite/prod`
 - `nova-pro/prod`
 - `nova-lite-2/prod`
- Ruta de S3 para la ruta de punto de comprobación entrenado posteriormente (`s3:customer-escrow-111122223333-smtj-<unique_id>/<training_run_name>`)

 Note

Evaluación de modelos de entrenados posteriormente

Para evaluar un modelo entrenado posteriormente después de un trabajo de entrenamiento de Nova SFT, siga estos pasos después de ejecutar un trabajo de entrenamiento correcto. Al final de los registros de entrenamiento, verá el mensaje de registro “Training is complete”. También encontrará un archivo `manifest.json` en su bucket de salida que contiene la ubicación de su punto de comprobación. Este archivo se ubicará dentro de un archivo `output.tar.gz` en la ubicación S3 de salida. Para continuar con la evaluación, utilice este punto de comprobación configurándolo como el valor para `run.model_name_or_path` en la configuración de la fórmula.

- `replica`: el número de instancias de computación que se van a utilizar para la inferencia distribuida (inferencia en varios nodos). Establezca `replica > 1` para habilitar la inferencia en varios nodos, lo que acelera la evaluación. Si se especifican tanto `instance_count` como `replica`, `instance_count` tiene prioridad. Tenga en cuenta que las réplicas múltiples solo se aplican a los trabajos de entrenamiento de SageMaker AI.
- `data_s3_path`: ruta de Amazon S3 del conjunto de datos de entrada. Este campo es obligatorio, pero siempre debe dejarse vacío.

- `mlflow_tracking_uri`: (opcional) la ubicación del servidor de seguimiento de MLflow (solo se necesita en SMHP)
- `mlflow_experiment_name`: (opcional) nombre del experimento para agrupar los procesamientos de ML relacionados
- `mlflow_run_name`: (opcional) nombre personalizado para un entrenamiento específico realizado dentro de un experimento

Configuración de evaluación

```
evaluation:  
  task: mmlu  
  strategy: zs_cot  
  subtask: abstract_algebra  
  metric: accuracy
```

- `task`: especifica la referencia o la tarea de evaluación que se va a utilizar. Entre las tareas admitidas se incluyen:
 - `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 el enfoque de evaluación:

- `zs_cot`: cadena de pensamientos de cero intentos: enfoque para realizar peticiones a modelos de lenguaje de gran tamaño que fomenta el razonamiento paso a paso sin necesidad de ejemplos explícitos.
- `fs_cot`: cadena de pensamiento de pocos pasos: enfoque que proporciona algunos ejemplos de razonamiento paso a paso antes de pedirle al modelo que resuelva un problema nuevo.
- `zs`: cero intentos: enfoque para resolver un problema sin ejemplos de entrenamiento anteriores.
- `gen_qa`: estrategia específica para utilizar su propio conjunto de datos.
- `judge`: estrategia específica para `mm_llm_judge` y un LLM como juez de Nova.
- `subtask`: opcional. Componentes específicos de la tarea de evaluación. Para obtener una lista completa de las subtareas disponibles, consulte [???](#).
 - Compruebe las subtareas compatibles en las tareas de referencia disponibles.
 - Debe eliminar este campo si no hay referencias de subtareas.
- `metric`: métrica de evaluación que se va a utilizar.
 - `accuracy`: porcentaje de respuestas correctas.
 - `exact_match`: para referencia matemática, devuelve la velocidad a la que las cadenas de entrada previstas coinciden exactamente con sus referencias.
 - `deflection`: para referencia de rechazo fuerte, devuelve la deflexión relativa al modelo base y la diferencia en las métricas de importancia.
- `all`:

Para `gen_qa`, utilice su propio conjunto de datos como punto de referencia y se devuelven las siguientes métricas:

- `rouge1`: mide la superposición de unigramas (palabras individuales) entre el texto generado y el de referencia.
- `rouge2`: mide la superposición de bigramas (dos palabras consecutivas) entre texto generado y de referencia.
- `rougeL`: mide la subsecuencia común más larga entre textos, por lo que puede haber lagunas en la coincidencia.
- `exact_match`: puntuación binaria (0 o 1) que indica si el texto generado coincide exactamente con el texto de referencia, carácter por carácter.
- `quasi_exact_match`: similar a la coincidencia exacta, pero más flexible, pues suele ignorar el uso de mayúsculas y minúsculas, los signos de puntuación y los espacios en blanco.

- `f1_score`: media armónica de precisión y recuperación que mide la superposición de palabras entre respuestas previstas y de referencia.
- `f1_score_quasi`: similar a `f1_score`, pero con una coincidencia más flexible, utiliza una comparación de texto normalizada que no tiene en cuenta pequeñas diferencias.
- `bleu`: mide la precisión de las coincidencias de n-gramas entre texto generado y de referencia, suele utilizarse en la evaluación de traducciones.

En el caso de `llm_judge` y `mm_llm_judge` con su propio conjunto de datos comparativo, devuelve las siguientes métricas:

- `a_scores`: número de aciertos para `response_A` en pasadas de evaluación hacia delante y hacia atrás.
- `a_scores_stderr`: error estándar de `response_A_scores` en juicios por pares.
- `b_scores`: mide el número de aciertos para `response_B` en pasadas de evaluación hacia delante y hacia atrás.
- `a_scores_stderr`: error estándar de `response_B_scores` en juicios por pares.
- `ties`: número de juicios en los que se evalúa `response_A` y `response_B` como iguales.
- `ties_stderr`: error estándar de `ties` en juicios por pares.
- `inference_error`: número de juicios que no se han podido evaluar adecuadamente.
- `score`: puntuación global basada en aciertos de pasadas hacia adelante y hacia atrás para `response_B`.
- `score_stderr`: puntuación global basada en aciertos de pasadas hacia adelante y hacia atrás para `response_B`.
- `inference_error_stderr`: error estándar de puntuación global en juicios por pares.
- `winrate`: probabilidad de que se prefiera `response_B` a `response_A` calculada utilizando probabilidad de Bradley-Terry.
- `lower_rate`: límite inferior (percentil 2,5) de la tasa de aciertos estimada a partir del muestreo de inicio.
- `upper_rate`: límite superior (percentil 97,5) de la tasa de aciertos estimada a partir del muestreo de inicio.

Configuración de inferencia (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 que se generarán. Debe ser un número entero. (No disponible para LLM Judge)
- `top_k`: número de tokens de mayor probabilidad que se deben tener en cuenta. Debe ser un número entero.
- `top_p`: umbral de probabilidad acumulada para el muestreo de tokens. Debe ser un valor flotante entre 1,0 y 0,0.
- `temperature`: asignación al azar en selección de tokens (mayor = más aleatorio), mantenga 0 para que el resultado sea determinista. De tipo flotante, el valor mínimo es 0.
- `top_logprobs`: el número de probabilidades logarítmicas principales que se devolverán en la respuesta de inferencia. El valor debe ser un número entero entre 0 y 20. Las probabilidades logarítmicas contienen los tokens resultantes considerados y las probabilidades de registro de cada token resultante devuelto en el contenido del mensaje.
- `reasoning_effort`: controla el comportamiento de razonamiento de los modelos capaces de razonar. Establezca `reasoning_effort` solo cuando `model_type` especifique un modelo con capacidad de razonamiento (actualmente, `amazon.nova-2-lite-v1:0:256k`). Las opciones disponibles son `null` (valor predeterminado si no se establece ninguno; desactiva el razonamiento), `low` o `high`.

Formato de salida de la probabilidad logarítmica

Cuando `top_logprobs` se configura en los ajustes de inferencia, el resultado de la evaluación incluye las probabilidades logarítmicas del token en los archivos de parquet. Cada posición de un token contiene un diccionario de los principales tokens candidatos con sus probabilidades logarítmicas siguiendo esta estructura:

```
{
  "Ġint": {"logprob_value": -17.8125, "decoded_value": " int"},
  "Ġthe": {"logprob_value": -2.345, "decoded_value": " the"}
}
```

Cada entrada de token contiene lo siguiente:

- `logprob_value`: el valor de probabilidad logarítmica del token
- `decoded_value`: la representación en cadena decodificada legible por humanos del token

El token tokenizador sin procesar se utiliza como clave del diccionario para garantizar la exclusividad, mientras que `decoded_value` proporciona una interpretación legible.

Ejemplos de fórmula de evaluación

Amazon Nova ofrece cuatro tipos diferentes de fórmulas de evaluación. Todas las fórmulas están disponibles en el [repositorio de fórmulas de Amazon SageMaker HyperPod de GitHub](#).

Fórmulas de referencia de texto general

Estas fórmulas le permiten evaluar las capacidades fundamentales de los modelos de Amazon Nova a través de un amplio conjunto de referencias solo de texto.

Formato de fórmula: `xxx_general_text_benchmark_eval.yaml`.

Fórmulas de referencia de uso de conjunto de datos propio

Estas fórmulas le permiten utilizar su propio conjunto de datos como referencia y comparar las salidas del modelo con las respuestas de referencia utilizando diferentes tipos de métricas.

Formato de fórmula: `xxx__bring_your_own_dataset_eval.yaml`.

Requisitos del conjunto de datos de uso propio

Formato de archivo:

- Archivo `gen_qa.jsonl` único que contiene ejemplos de evaluación. El nombre del archivo debe llamarse exactamente `gen_qa.jsonl`.
- Debe cargar el conjunto de datos en una ubicación de S3 a la que puedan acceder los trabajos de entrenamiento de SageMaker AI.
- El archivo debe seguir el formato de esquema requerido para un conjunto de datos general de preguntas y respuestas.

Requisitos del formato de esquema: cada línea del archivo `.jsonl` debe ser un objeto JSON con los siguientes campos:

- Campos obligatorios.

query: cadena que contiene la pregunta o la instrucción que necesita una respuesta.

response: cadena que contiene la salida esperada del modelo.

- Campos opcionales.

system: cadena que contiene la petición del sistema que establece el comportamiento, el rol o la personalidad del modelo de IA antes de que procese la consulta.

images: matriz que contiene una lista de objetos con atributos de datos (cadenas de imágenes codificadas en Base64).

metadata: cadena que contiene los metadatos asociados a la entrada con fines de etiquetado.

Ejemplo 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 un conjunto de datos personalizado, modifique la fórmula de evaluación agregando los siguientes campos obligatorios, sin cambiar la configuración existente:

```
evaluation:
  task: gen_qa
  strategy: gen_qa
  metric: all
```

Limitaciones

- Solo se permite un archivo `.jsonl` por evaluación.
- El archivo debe seguir estrictamente el esquema definido.

Uso de sus propias métricas

Puede usar sus propias métricas para personalizar completamente el flujo de trabajo de evaluación del modelo con funciones personalizadas de preprocesamiento, posprocesamiento y métricas. El preprocesamiento le permite procesar los datos de entrada antes de enviarlos al servidor de inferencia, y el posprocesamiento le permite personalizar el cálculo de las métricas y devolver métricas personalizadas en función de sus necesidades.

Siga estos pasos para crear sus propias métricas con el SDK de evaluación personalizada:

1. Si no lo ha hecho, [cree primero una función AWS Lambda](#) en su Cuenta de AWS.
2. Descargue el archivo `nova-custom-eval-layer.zip` ya creado del [repositorio de GitHub](#). Puede usar este SDK de evaluación personalizada de Nova de código abierto para validar las cargas útiles de entrada y salida de tu función personalizada y proporcionar una interfaz unificada para integrarla con la evaluación de métricas propia de Nova durante el entrenamiento.
3. Use el siguiente comando para cargar la capa de Lambda personalizada:

```
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. Agregue esta capa como capa personalizada a la función de Lambda, junto con la capa de AWS necesaria: AWSLambdaPowerToolsPythonV3-python312-arm64 (necesaria para la dependencia pydantic).
5. Actualice el código de Lambda usando el ejemplo proporcionado y modifique el código según sea necesario. Este código de ejemplo crea una función de Lambda para la evaluación personalizada de Nova con pasos de preprocesamiento y posprocesamiento destinados a la evaluación del 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
)

```

- Otorgue a Lambda acceso al trabajo de evaluación. Asegúrese de que el rol de puesta en marcha especificado para el trabajo de evaluación incluya una política para invocar la función de Lambda. A continuación, se muestra un ejemplo 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. Revise el esquema de la carga útil de Lambda. La tabla siguiente muestra el esquema de solicitud y respuesta de Lambda. Puede validar el esquema con el SDK de evaluación personalizada de Nova.

	Carga útil de la solicitud de Lambda	Carga útil de la respuesta de Lambda
Preprocesador	<pre>{ "process_type": "preprocess", "data": { "system": "You are a helpful assistant", "prompt": "What is 2+2?", "gold": "4" } }</pre>	<pre>{ "statusCode": 200, "body": { "system": "You are a helpful assistant that can substitute * for addition", "prompt": "What is 2*2?", "gold": "4" } }</pre>
Postprocesador	<pre>{ "process_type": "postprocess", "data": { "prompt": "What is 2+2?", "inference_output": "2+2=4", "gold": "4" } }</pre>	<pre>{ "statusCode": 200, "body": [{"metric": "accuracy", "value": 1.0}, {"metric": "f1_score", "value": 1.0}, {"metric": "exact_match", "value": 1}, {"metric": "length_ratio", "value": 0.8}] }</pre>

8. Modifique el archivo de la fórmula. A continuación se muestra un ejemplo.

```
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`: el nombre de recurso de Amazon (ARN) de la función de Lambda que gestiona el preprocesamiento y el posprocesamiento.
- `lambda_type`: "custom_metrics" o "rft".
- `preprocessing`: si se deben habilitar las operaciones de preprocesamiento personalizadas.
- `postprocessing`: si se deben habilitar las operaciones de posprocesamiento personalizadas.
- `aggregation`: función de agregación integrada (opciones válidas: mínimo, máximo, promedio, suma).

Limitaciones

- El uso de sus propias métricas solo se aplica a los conjuntos de datos de entrada de texto.
- No se admiten los conjuntos de datos de entrada multimodales.
- El paso de preprocesamiento no procesa el campo de metadatos.

Fórmulas de referencia de Nova LLM como juez

Nova LLM Judge es una característica de evaluación de modelos que le permite comparar la calidad de las respuestas de un modelo con las respuestas de un modelo de referencia mediante un conjunto de datos personalizado. Acepta un conjunto de datos que contiene peticiones, respuestas de referencia y respuestas de desafío, y utiliza un modelo de Nova Judge para proporcionar una métrica de tasa de aciertos basada en probabilidad de [Bradley-Terry](#) con comparaciones por pares. Formato de fórmula: `xxx_llm_judge_eval.yaml`.

Requisitos del conjunto de datos de Nova LLM

Formato de archivo:

- Archivo `llm_judge.jsonl` único que contiene ejemplos de evaluación. El nombre del archivo debe llamarse exactamente `llm_judge.jsonl`.
- Debe cargar el conjunto de datos en una ubicación de S3 a la que puedan acceder los trabajos de entrenamiento de SageMaker AI.
- El archivo debe seguir el formato de esquema requerido para el conjunto de datos `llm_judge`.
- El conjunto de datos de entrada debe garantizar que todos los registros tengan una longitud de contexto inferior a 12 000.

Formato de esquema: cada línea del archivo `.jsonl` debe ser un objeto JSON con los siguientes campos.

- Campos obligatorios.

`prompt`: cadena que contiene la petición de la respuesta generada.

`response_A`: cadena que contiene la respuesta de referencia.

`response_B`: cadena que contiene la respuesta alternativa que se comparará con la respuesta de referencia.

Ejemplo 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 un conjunto de datos personalizado, modifique la fórmula de evaluación con los siguientes campos obligatorios, sin cambiar ningún contenido:

```
evaluation:
  task: llm_judge
  strategy: judge
  metric: all
```

Limitaciones

- Solo se permite un archivo `.jsonl` por evaluación.
- El archivo debe seguir estrictamente el esquema definido.
- Los modelos de Nova Judge son los mismos en todas las especificaciones micro, lite y pro.
- Actualmente no se admiten modelos de juez personalizados.

LLM como juez de Nova de fórmulas de referencia multimodales (imágenes)

LLM como juez de Nova para entradas multimodales (imágenes) es una característica de evaluación de modelos que le permite comparar la calidad de las respuestas de un modelo con las respuestas de un modelo de referencia mediante un conjunto de datos personalizado. Acepta un conjunto de datos que contiene peticiones, respuestas de referencia y respuestas de desafío, así como imágenes en forma de cadena codificada en Base64. Utiliza un modelo juez de Nova para proporcionar una métrica de tasa de aciertos basada en probabilidad de [Bradley-Terry](#) con comparaciones por pares. Formato de fórmula: `xxx_mm_llm_judge_eval.yaml`.

Requisitos del conjunto de datos de Nova LLM

Formato de archivo:

- Archivo `mm_llm_judge.jsonl` único que contiene ejemplos de evaluación. El nombre de archivo debe ser `llm_judge.jsonl`.
- Debe cargar el conjunto de datos en una ubicación de S3 a la que puedan acceder los trabajos de entrenamiento de SageMaker AI.
- El archivo debe seguir el formato de esquema requerido para el conjunto de datos `mm_llm_judge`.
- El conjunto de datos de entrada debe garantizar que todos los registros tengan una longitud de contexto inferior a 12 000, sin incluir el atributo de la imagen.

Formato de esquema: cada línea del archivo `.jsonl` debe ser un objeto JSON con los siguientes campos.

- Campos obligatorios.

`prompt`: cadena que contiene la petición de la respuesta generada.

`images`: matriz que contiene una lista de objetos con atributos de datos (los valores son cadenas de imágenes codificadas en Base64).

`response_A`: cadena que contiene la respuesta de referencia.

`response_B`: cadena que contiene la respuesta alternativa que se comparará con la respuesta de referencia.

Ejemplo de entrada

Para facilitar la lectura, el siguiente ejemplo incluye nuevas líneas e indentaciones, pero en el conjunto de datos real, cada registro debe estar en una sola línea.

```
{
  "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 un conjunto de datos personalizado, modifique la fórmula de evaluación con los siguientes campos obligatorios, sin cambiar ningún contenido:

```
evaluation:
  task: mm_llm_judge
  strategy: judge
  metric: all
```

Limitaciones

- Solo se permite un archivo `.jsonl` por evaluación.
- El archivo debe seguir estrictamente el esquema definido.
- Los modelos MM como juez de Nova solo admiten referencias de imagen.
- Los modelos MM como juez de Nova son los mismos en todas las especificaciones de Amazon Nova Micro, Amazon Nova Lite y Amazon Nova Pro.
- Actualmente no se admiten modelos de juez personalizados.
- No se admite el URI de imagen de Amazon S3.
- El conjunto de datos de entrada debe garantizar que todos los registros tengan una longitud de contexto inferior a 12 000, sin incluir los atributos de imagen.

Evaluación de puntos de control de CPT (entrenamiento previo continuo)

La evaluación con modelos de CPT (entrenamiento previo continuo) puede ser más difícil que con los modelos sometidos a un SFT (refinamiento supervisado), ya que los modelos de CPT suelen carecer de la capacidad de seguir instrucciones. En lugar de seguir las instrucciones, el modelo de CPT funcionará como modelos de finalización, lo que significa que solo intentará continuar con el patrón proporcionado con la secuencia de tokens de entrada. Dada esta limitación, es posible que los conjuntos de datos de evaluación típicos no funcionen correctamente debido al formato de “preguntas y respuestas” de las entradas. Es decir, en lugar de responder a la pregunta, el modelo simplemente intentará continuar con la misma pregunta. Sin embargo, al formatear los conjuntos de datos de una manera específica para hacer peticiones a modelos con un estilo de finalización, podemos comprender el rendimiento del modelo.

Siga los pasos que se indican a continuación para comprender cómo llevar a cabo una evaluación en un modelo continuo entrenado previamente con el flujo de trabajo de evaluación de Nova Forge.

Preparación y formateo del conjunto de datos

La evaluación de un modelo de CPT aprovecha el flujo de trabajo ya existente de [conjunto de datos propio](#) que ya se incluye en la experiencia de evaluación del modelo de Nova Forge. Sin embargo, las consultas incluidas en el conjunto de datos deben tener un formato puramente de “finalización”, ya que los modelos de CPT no responderán a las peticiones de tipo pregunta estándar de la misma manera que lo haría un modelo de SFT.

Otra limitación importante y frecuente de los modelos que se han sometido únicamente al CPT es su incapacidad para generar tokens STOP o de fin de secuencia, lo que significa que el modelo continuará generando tokens hasta que se detenga forzosamente (por ejemplo, con el parámetro `max_new_tokens`). Dada esta limitación, la práctica recomendada consiste en evaluar los modelos con respuestas de un solo token (como las de opción múltiple) para garantizar que el modelo no continúe generando salidas no deseadas que no sean necesarias después de la petición.

Por ejemplo, un conjunto de datos de evaluación típico (como MMLU, GPQA, MATH, etc.) podría pedir al modelo una pregunta 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.)
```

Sin embargo, un modelo de CPT no entendería cómo responder adecuadamente a esta pregunta debido a la falta de refinamiento sobre seguimiento de las instrucciones. Por lo tanto, se deben hacer peticiones a los modelos de CPT con un estilo de finalización, como, por ejemplo:

```
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.)
```

Tras la comprobación por inferencia, las logprobs de salida generadas por el modelo proporcionarán detalles sobre si el modelo procesó correctamente la entrada y generó la respuesta correcta. No se garantiza que el modelo produzca siempre la respuesta exacta (en este caso, la letra D) esperada, pero debería estar presente en las logprobs si el modelo funciona correctamente.

Otro ejemplo de petición con estilo de finalización sin opción múltiple:

```
The capital of France is

(Expected answer of Paris)
```

Es de esperar que el modelo produzca la respuesta “París” o que el token correspondiente a “París” aparezca en algún lugar de la salida de las logprobs.

Formateo del conjunto de datos de entrada

La evaluación del CPT aprovecha el flujo de trabajo de [conjunto de datos propio](#) existente. Los datos deben tener el formato de “respuesta a la consulta” en un archivo JSONL separado por saltos de línea.

Ejemplo de un conjunto de datos con 4 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 línea debe contener:

- query: texto de la petición para finalizarlo
- response: finalización prevista (dato real)

El modelo recibirá una entrada de texto sin procesar sin formato de chat. Por lo general, los modelos de CPT aún no están entrenados con tokens especiales y no responderán correctamente a las plantillas de chat, por lo que, al hacer peticiones al modelo, SOLO se enviará al modelo la cadena proporcionada en la consulta (con un token [BOS] adicional agregado automáticamente).

Configuración de fórmulas

A continuación, se muestra un ejemplo de una fórmula que está configurada para evaluar un modelo de 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
```

Cambios clave para la evaluación de CPT:

- checkpoint_is_instruction_tuned: "false"

Se trata de un nuevo parámetro agregado específicamente para permitir las ejecuciones de evaluaciones en puntos de control de CPT. Si se establece checkpoint_is_instruction_tuned en

false, se deshabilitará la plantilla de chat predeterminada de Amazon Nova que normalmente incluye la petición de entrada.

- `top_logprobs`: 5

Las probabilidades logarítmicas (logprobs) revelan la distribución de confianza del modelo entre los posibles tokens siguientes, lo que le permite evaluar si el modelo ha aprendido los resultados esperados durante el entrenamiento previo. Por lo general, si el modelo funciona según lo previsto, deberíamos ver la respuesta esperada (es decir, "A", "B", etc.) como el token de salida generado o como token en las logprobs.

- `max_new_tokens`: 1

Por lo general, los modelos de CPT aún no se han entrenado para generar tokens especiales "STOP" o de "fin de secuencia" que indiquen cuándo detener la inferencia. Esto significa que, por lo general, el modelo continuará generando nuevos tokens hasta que se alcance la longitud de tokens máxima específica, lo que generará inferencia innecesaria. Por lo general, la forma más eficaz de hacer peticiones al modelo es limitar `max_new_tokens` a 1 y proporcionar una petición que pueda evaluar el modelo a partir de una sola respuesta (como una pregunta de opción múltiple). Si se establece `max_new_tokens` en 1, se garantiza que no se generen tokens no deseados adicionales.

Parámetros clave

- `checkpoint_is_instruction_tuned`: debe establecerse en "false" (o false como booleano) para deshabilitar las plantillas de chat.
- `top_logprobs`: 5, se recomienda para ver cómo aprende el modelo durante el CPT.
- `task`: debe ser `gen_qa`. Los modelos de CPT no pueden usar puntos de referencia de seguimiento de instrucciones como MMLU o MATH.
- `strategy`: debe ser `gen_qa`.
- `max_new_tokens`: se recomienda mantenerlo bajo (1-5), ya que los modelos de CPT llevan a cabo la finalización y no la generación.

Ejecución de trabajos de entrenamiento de evaluación

Comience un trabajo de entrenamiento con el siguiente ejemplo de cuaderno. Use el siguiente cuaderno como ejemplo para llevar a cabo el trabajo de entrenamiento de evaluación. Para obtener

más información, consulte [Uso de un estimador de SageMaker AI para ejecutar un trabajo de entrenamiento](#).

Tablas de referencia

Antes de ejecutar el cuaderno, consulte las siguientes tablas de referencia para seleccionar la URI de la imagen y las configuraciones de instancias.

Selección de la URI de la imagen

Fórmula	URI de imagen
URI de imagen de evaluación	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-TJ-Eval-V2-latest

Selección del tipo y el recuento de instancias

Modelo	Tipo de trabajo	Tipo de instancia	Recuento de instancia recomendado	Recuento de instancias permitido
Amazon Nova Micro	Evaluación (SFT/DPO)	g5.12xlarge	1	1-16
Amazon Nova Lite	Evaluación (SFT/DPO)	g5.12xlarge	1	1-16
Amazon Nova Pro	Evaluación (SFT/DPO)	p5.48xlarge	1	1-16

Cuaderno de ejemplo

En el siguiente cuaderno de ejemplo se muestra cómo ejecutar un trabajo de entrenamiento de evaluación.

```
# 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})

```

Evaluación y análisis de los resultados de la evaluación

Una vez que el trabajo de evaluación haya finalizado satisfactoriamente, podrá evaluar los resultados y analizarlos mediante los pasos siguientes.

Para evaluar y analizar los resultados, siga estos pasos.

1. Comprenda la estructura de la ubicación de salida. Los resultados se almacenan en la ubicación de salida de Amazon S3 especificada como un archivo comprimido:

```

s3://your-bucket/output/benchmark-name/
### job_name/
    ### output/
        ### output.tar.gz

```

2. Descargue el archivo `output.tar.gz` de su bucket. Extraiga el contenido para revelarlo.

```

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`: archivo JSON de métricas de salida
- `details_<task_name>_#_<datetime>.parquet`: archivo de resultados de inferencias (excepto `strong_reject`)
- `events.out.tfevents.[timestamp]`: archivo de salida de TensorBoard

- `inference_output.jsonl`: archivo de salida de inferencias limpio (solo para tareas `gen_qa`)
3. Vea los resultados en TensorBoard. Para visualizar sus métricas de evaluación:
 1. Cargue la carpeta extraída en un bucket de S3
 2. Navegue hasta SageMaker AI TensorBoard.
 3. Seleccione sus “carpetas de S3”
 4. Añada la ruta de la carpeta de S3
 5. Espere a que se complete la sincronización
 4. Analice los resultados de las inferencias. Todas las tareas de evaluación, excepto `llm_judge` y `strong_reject`, tendrán los siguientes campos de análisis en el resultado de la inferencia.
 - `full_prompt`: la petición completa del usuario enviada al modelo utilizado para la tarea de evaluación.
 - `gold`: el campo que contiene las respuestas correctas especificadas en el conjunto de datos.
 - `metrics`: el campo que contiene las métricas evaluadas en la inferencia individual. Los valores que requieren agregación no tendrían ningún valor en los resultados de la inferencia individuales.
 - `predictions`: el campo que contiene una lista de los resultados del modelo para la petición dada.
 - `pred_logits`: el campo que contiene los tokens resultantes considerados y las probabilidades de registro de cada token resultante devuelto en el contenido del mensaje.

Al observar estos campos, puede determinar la causa de las diferencias métricas y comprender el comportamiento de los modelos personalizados.

Para `llm_judge`, el archivo de salida de inferencias contiene los siguientes campos en el campo de métricas por par de evaluaciones.

- `forward_output`: las preferencias brutas de Judge al evaluar en orden (`response_A`, `response_B`).
- `backward_output`: las preferencias brutas de Judge al evaluar en orden inverso (`response_B`, `response_A`).
- `Pairwise metrics`: métricas que se calculan por pares de evaluaciones hacia adelante y hacia atrás, incluidas `a_scores`, `b_scores`, `ties`, `inference-score` y `score`.

 Note

Las métricas agrupadas como `winrate` solo están disponibles en los archivos de resultados de resumen, no por valoración individual.

Para `gen_qa`, el archivo `inference_output.jsonl` contiene los siguientes campos para cada objeto JSON:

- `petición`: última petición enviada al modelo
- `inferencia`: salida de inferencia sin procesar del modelo
- `gold`: la respuesta objetivo del conjunto de datos de entrada
- `metadata`: la cadena de metadatos del conjunto de datos de entrada, si se proporciona

Prácticas recomendadas y solución de problemas de evaluación

Prácticas recomendadas

A continuación se enumeran algunas de las prácticas recomendadas para el proceso de evaluación.

- Mantenga las rutas de salida organizadas por modelo y tipo de referencia.
- Mantenga convenciones de nomenclatura coherentes para facilitar el seguimiento.
- Guarde los resultados extraídos en un lugar seguro.
- Supervise el estado de sincronización de TensorBoard para que los datos se carguen correctamente.

Solución de problemas

Puede utilizar el grupo de registros de CloudWatch `/aws/sagemaker/TrainingJobs` para los registros de errores de los trabajos de entrenamiento.

Fallo del núcleo del motor

Problema:

Si ve lo siguiente:

```
RuntimeError: Engine core initialization failed.
```

Causa:

Aunque se trata de un error general que puede tener varias causas, suele producirse cuando no coinciden el punto de control del modelo que se intenta cargar y el tipo de modelo especificado. Por ejemplo, quiere evaluar un punto de control de un modelo de Nova 2.0 Lite refinado, pero el tipo de modelo que proporciona es de la versión 1.0, por ejemplo, `amazon.nova-micro-v1:0:128k`

La asignación correcta debería ser la siguiente:

```
model_type: amazon.nova-2-lite-v1:0:256k
model_name_or_path: nova-lite-2/prod # or s3://escrow_bucket/model_location
```

Prevención:

Compruebe que `model_name_or_path` se haya asignado al `model_type` correcto antes de enviar el trabajo de evaluación.

Subtareas disponibles

A continuación, se indican las subtareas disponibles para la evaluación de modelos en varios dominios, como MMLU (Massive Multitask Language Understanding), BBH (Big Bench Hard), MATH y MMMU (Massive Multi-discipline Multimodal Understanding). Estas subtareas le permiten evaluar el rendimiento del modelo en función de capacidades y áreas de conocimiento 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"  
]
```

Matemático

```
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",
```

Evalúe sus modelos de Nova personalizados utilizando varios métodos y métricas de evaluación.

En esta sección:

- [Evaluación del modelo de razonamiento](#)

- [Evaluación del RFT](#)
- [Implementación de funciones de recompensas](#)

Evaluación del modelo de razonamiento

Descripción general

La compatibilidad con el modelo de razonamiento permite la evaluación con modelos de Nova capaces de razonar que realizan un razonamiento interno explícito antes de generar las respuestas finales. Esta característica utiliza el control de la API mediante el parámetro `reasoning_effort` para activar o desactivar de forma dinámica la funcionalidad de razonamiento, lo que podría mejorar la calidad de la respuesta en tareas analíticas complejas.

Modelos compatibles

- `amazon.nova-2-lite-v1:0:256k`

Configuración de fórmulas

Active el razonamiento agregando el parámetro `reasoning_effort` a la sección `inference` de su 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 del parámetro reasoning_effort

El parámetro `reasoning_effort` controla el comportamiento de razonamiento de los modelos con capacidad de razonamiento.

Requisitos previos

- **Compatibilidad del modelo:** establezca `reasoning_effort` solo cuando `model_type` especifique un modelo con capacidad de razonamiento (actualmente, `amazon.nova-2-lite-v1:0:256k`).
- **Gestión de errores:** si se utiliza `reasoning_effort` con modelos no compatibles, se producirá un error: `ConfigValidationError: "Reasoning mode is enabled but model '{model_type}' does not support reasoning. Please use a reasoning-capable model or disable reasoning mode."`

Opciones disponibles

Opción	Comportamiento	Límite de tokens	Caso de uso
null (por defecto)	Desactiva el modo de razonamiento	N/A	Evaluación estándar sin sobrecarga de razonamiento
low	Permite razonar con restricciones	4000 tokens para el razonamiento interno	Escenarios que requieren un razonamiento conciso;

Opción	Comportamiento	Límite de tokens	Caso de uso
			optimiza para una mayor velocidad y rentabilidad
high	Permite razonar sin restricciones	El razonamiento interno no tiene un límite de tokens	Problemas complejos que requieren un análisis exhaustivo y un razonamiento paso a paso

Método de entrenamiento	Opciones disponibles	Cómo se configura
SFT (refinamiento supervisado)	Solo Alto o Desactivado	Utilice reasoning_enabled: true (alto) o reasoning_enabled: false (desactivado).
RFT (refinamiento por refuerzo)	Bajo, Alto o Desactivado	Utilice reasoning_effort: bajo o reasoning_effort: alto. Omita el campo para deshabilitarlo.
Evaluación	Bajo, Alto o Desactivado	Utilice reasoning_effort: bajo o reasoning_effort: alto. Utilice nulo para deshabilitarlo.

¿Cuándo habilitar el razonamiento?

Cuándo se debe usar el modo de razonamiento (**low** o **high**)

- Tareas complejas de resolución de problemas (matemáticas, acertijos de lógica, programación).
- Preguntas analíticas de varios pasos que requieran un razonamiento intermedio.
- Tareas en las que las explicaciones detalladas o el pensamiento paso a paso mejoren la precisión.
- Escenarios en los que se dé prioridad a la calidad de la respuesta por encima de la velocidad.

Cuándo se debe usar el modo sin razonamiento (**null** u omita el parámetro)

- Preguntas y respuestas sencillas o consultas fácticas.
- Tareas de escritura creativa.

- Tareas en las que los tiempos de respuesta más rápidos sean fundamentales.
- Evaluación comparativa del rendimiento, en la que debe excluirse la sobrecarga de razonamiento.
- Priorización de la rentabilidad cuando el razonamiento no mejore el rendimiento de la tarea.

Solución de problemas

Error: "Reasoning mode is enabled but model does not support reasoning"

Causa: el parámetro `reasoning_effort` está establecido en un valor que no es null, pero el valor especificado para `model_type` no admite el razonamiento.

Solución:

- Compruebe que el tipo de modelo sea `amazon.nova-2-lite-v1:0:256k`.
- Si utiliza un modelo diferente, cámbielo a un modelo que pueda razonar o elimine el parámetro `reasoning_effort` de la fórmula

Evaluación del RFT

¿Qué es la evaluación del RFT?

La evaluación del RFT le permite evaluar el rendimiento del modelo mediante funciones de recompensas personalizadas antes, durante o después del entrenamiento de aprendizaje por refuerzo. A diferencia de las evaluaciones estándar que utilizan métricas predefinidas, la evaluación del RFT le permite definir sus propios criterios de éxito mediante una función de Lambda que puntúa los resultados del modelo en función de sus requisitos específicos.

¿Por qué se debe evaluar con el RFT?

La evaluación es crucial para determinar si el proceso de refinamiento de RL:

- Ha mejorado la alineación del modelo con su caso de uso específico y sus valores humanos.
- Ha mantenido o mejorado las capacidades del modelo en tareas clave.
- Ha evitado efectos secundarios no deseados, como la reducción de la objetividad, el aumento de los detalles o la degradación del rendimiento en otras tareas.
- Ha cumplido con los criterios de éxito personalizados, tal como los define su función de recompensas.

¿Cuándo se debe utilizar la evaluación del RFT?

Utilice la evaluación del RFT en los siguientes escenarios:

- Antes del entrenamiento RFT: establezca métricas de línea de base en su conjunto de datos de evaluación.
- Durante el entrenamiento RFT: supervise el progreso del entrenamiento con puntos de control intermedios.
- Después del entrenamiento RFT: valide que el modelo final cumpla con sus requisitos.
- Comparación de modelos: evalúe varias versiones del modelo con criterios de recompensa coherentes.

Note

Utilice la evaluación del RFT cuando necesite métricas personalizadas y específicas de un dominio. Para una evaluación de uso general (precisión, perplejidad, BLEU), utilice métodos de evaluación estándar.

Requisitos del formato de los datos

Estructura de los datos de entrada

Los datos de entrada de la evaluación del RFT deben seguir el formato de refinamiento por refuerzo de OpenAI. Cada ejemplo es un objeto JSON que contiene lo siguiente:

- `messages`: matriz de turnos conversacionales con los roles `system` y `user`
- `reference_answer`: datos de salida o reales esperados que utiliza la función de recompensas para la puntuación

Ejemplo de formato de datos

```
{
  "messages": [
    {
      "role": "user",
      "content": [
```

```

    {
      "type": "text",
      "text": "Solve for x. Return only JSON like {\"x\": <number>}. Equation: 2x +
5 = 13"
    }
  ],
  "reference_answer": {
    "x": 4
  }
}

```

Limitaciones actuales

- Solo texto: no se admiten entradas multimodales (imágenes, audio, video).
- Conversaciones de turno único: solo admite mensajes de un solo usuario (no se admiten diálogos de varios turnos).
- Formato JSON: los datos de entrada deben estar en formato JSONL (un objeto JSON por línea).
- Resultados del modelo: la evaluación se lleva a cabo en las terminaciones generadas a partir del modelo especificado.

Preparación de la fórmula de evaluación

Cuaderno de ejemplo

Para ver un ejemplo completo, consulte [Cuadernos de evaluación](#).

Configuración de fórmula de muestra

```

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>

```

Funciones de recompensas predefinidas

Hay dos funciones de recompensas predefinidas (`prime_code` y `prime_math`) disponibles como capa de Lambda para una integración fácil con las funciones de Lambda del RFT.

Descripción general

Estas funciones predefinidas ofrecen capacidades de evaluación listas para usar para:

- `prime_code`: generación de código y evaluación de la corrección
- `prime_math`: evaluación del razonamiento matemático y la resolución de problemas

Configuración rápida

1. Descargue la capa de Lambda de las [versiones de nova-custom-eval-sdk](#).
2. Publique la capa de Lambda mediante la Interfaz de la línea de comandos de 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. Agregue la capa a la función de Lambda en la Consola de administración de AWS (seleccione preset-function-layer en la capa personalizada y agregue también AWSSDKPandas-Python312 para dependencias de NumPy).
4. Impórtela y úsela en el código de Lambda:

```
from prime_code import compute_score # For code evaluation
from prime_math import compute_score # For math evaluation
```

Función prime_code

Evalúa las tareas de generación de código de Python mediante la ejecución del código en casos de prueba y la medición de la corrección.

Ejemplo de formato de conjunto de datos 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"]}}
```

Características principales de

- Extracción automática de código de bloques de código Markdown
- Detección de funciones y pruebas basadas en llamadas
- Ejecución de casos de prueba con protección de tiempo de espera
- Comprobaciones de compilación y validación de la sintaxis
- Informes de errores detallados con rastreos

Función prime_math

Evalúa el razonamiento matemático y las capacidades de resolución de problemas con soporte matemático simbólico.

Formato de entrada

```
{"messages":[{"role":"user","content":"What is the derivative of  $x^2 + 3x?$ ."}], "reference_answer": "2*x + 3"}
```

Características principales de

- Evaluación matemática simbólica con SymPy
- Múltiples formatos de respuesta (LaTeX, texto sin formato, simbólico)
- Comprobación de equivalencia matemática
- Normalización y simplificación de expresiones

Requisitos del formato de los datos

Para la evaluación de código

- Entradas: matriz de argumentos de funciones (tipos adecuados: enteros, cadenas, etc.)
- Salidas: matriz de valores de devolución esperados (tipos adecuados: booleanos, números, etc.)
- Código: debe estar en Python con definiciones de funciones claras

Para la evaluación matemática

- Respuesta de referencia: expresión matemática o valor numérico
- Respuesta: puede ser LaTeX, texto plano o notación simbólica
- Equivalencia: se comprueba simbólicamente, no solo la coincidencia de cadenas

Prácticas recomendadas

- Utilice los tipos de datos adecuados en los casos de prueba (números enteros frente a cadenas, valores booleanos frente a “verdaderos”).
- Proporcione firmas de funciones claras en los problemas de código.
- Incluya casos extremos en las entradas de prueba (cero, números negativos, entradas vacías).
- Formatee las expresiones matemáticas de forma coherente en las respuestas de referencia.
- Pruebe la función de recompensas con datos de ejemplo antes de la implementación.

Gestión de errores

Ambas funciones incluyen una sólida gestión de errores para:

- Errores de compilación en el código generado
- Excepciones de tiempo de ejecución durante la ejecución
- Datos de entrada incorrectos
- Escenarios de tiempo de espera para bucles infinitos
- Expresiones matemáticas no válidas

Creación de la función de recompensas

Requisitos del ARN de Lambda

El ARN de Lambda debe seguir este formato:

```
"arn:aws:lambda:*:*:function:*SageMaker*"
```

Si Lambda no tiene este esquema de nombres, el trabajo fallará y mostrará este error:

```
[ERROR] Unexpected error: lambda_arn must contain one of: ['SageMaker', 'sagemaker', 'Sagemaker'] when running on SMHP platform (Key: lambda_arn)
```

Formato de la solicitud de Lambda

La función de Lambda recibe datos en este formato:

```
[
  {
    "id": "sample-001",
    "messages": [
      {
        "role": "user",
        "content": [
          {
            "type": "text",
            "text": "Do you have a dedicated security team?"
          }
        ]
      }
    ]
  }
]
```

```

    },
    {
      "role": "nova_assistant",
      "content": [
        {
          "type": "text",
          "text": "As an AI developed by Company, I don't have a dedicated security
team..."
        }
      ]
    }
  ],
  "reference_answer": {
    "compliant": "No",
    "explanation": "As an AI developed by Company, I do not have a traditional
security team..."
  }
}
]

```

Note

La estructura del mensaje incluye la matriz content anidada, que coincide con el formato de datos de entrada. El último mensaje con el rol nova_assistant contiene la respuesta generada por el modelo.

Formato de la respuesta de Lambda

La función de Lambda debe devolver datos en este 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 respuesta

- **id**: debe coincidir con el ID de muestra de entrada
- **aggregate_reward_score**: puntuación general (normalmente de 0,0 a 1,0)
- **metrics_list**, matriz de métricas individuales con:
 - **name**: identificador de la métrica (por ejemplo, “precisión”, “fluidez”)
 - **value**: puntuación de la métrica (normalmente de 0,0 a 1,0)
 - **type**: “Métrica” (para informes) o “Recompensa” (utilizada en el entrenamiento)

Permisos de IAM

Permisos necesarios

El rol de ejecución de SageMaker debe tener permisos para invocar la función de Lambda. Agregue esta política al rol de ejecución de SageMaker:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "lambda:InvokeFunction"
      ],
      "Resource": "arn:aws:lambda:region:account-id:function:function-name"
    }
  ]
}
```

Rol de ejecución de Lambda

El rol de ejecución de una función de Lambda necesita permisos de ejecución de Lambda básicos:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "logs:CreateLogGroup",
        "logs:CreateLogStream",
        "logs:PutLogEvents"
      ],
      "Resource": "arn:aws:logs:*:*:*"
    }
  ]
}
```

Si la función de Lambda accede a otros servicios de AWS (por ejemplo, S3 para los datos de referencia o DynamoDB para el registro), agregue esos permisos al rol de ejecución de Lambda.

Ejecución del trabajo de evaluación

1. Prepare los datos: formatee los datos de evaluación de acuerdo con los requisitos de formato de los datos y cargue el archivo JSONL en S3: `s3://your-bucket/eval-data/eval_data.jsonl`.
2. Configure la fórmula, actualice la fórmula de muestra con la configuración:
 - Establezca `model_name_or_path` en la ubicación del modelo.
 - Establezca `lambda_arn` en el ARN de la función de recompensas.
 - Establezca `output_s3_path` en la ubicación de salida deseada.
 - Ajuste los parámetros de `inference` según sea necesario.

Guarde la fórmula como `rft_eval_recipe.yaml`.

3. Ejecute la evaluación, ejecute el trabajo de evaluación con el cuaderno proporcionado: [Cuadernos de evaluación](#).
4. Supervise el progreso, supervise el trabajo de evaluación mediante:
 - Consola de SageMaker: compruebe el estado y los registros de los trabajos.
 - Registros de CloudWatch: consulte los registros de ejecución detallados.
 - Registros de Lambda: depure problemas de la función de recompensas.

Descripción de los resultados de la evaluación

Formato de salida

El trabajo de evaluación envía los resultados a la ubicación de S3 especificada en formato JSONL. Cada línea contiene los resultados de la evaluación de una muestra:

```
{
  "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

El resultado del trabajo de evaluación del RFT es idéntico al formato de la respuesta de Lambda. El servicio de evaluación analiza la respuesta de la función de Lambda sin modificaciones, lo que garantiza la coherencia entre los cálculos de recompensas y los resultados finales.

Interpretación de los resultados

Puntuación total de recompensas

- Rango: normalmente de 0,0 (peor) a 1,0 (mejor), pero depende de la implementación
- Propósito: un solo número que resume el rendimiento general
- Uso: comparación de modelos, seguimiento de las mejoras con respecto al entrenamiento

Métricas individuales

- Tipo de métrica: métricas informativas para el análisis
- Tipo de recompensa: métricas utilizadas durante el entrenamiento RFT
- Interpretación: unos valores más altos suelen indicar un mejor rendimiento (a menos que diseñe métricas inversas)

Puntos de referencia de rendimiento

Lo que constituye un rendimiento “bueno” depende de su caso de uso:

Intervalo de puntuación	Interpretación	Action
Entre 0,8 y 1,0	Excelente	Modelo listo para su implementación
Entre 0,6 y 0,8	Buena	Podría beneficiarse de mejoras menores
Entre 0,4 y 0,6	Regular	Necesita una mejora importante
Entre 0,0 y 0,4	Deficiente	Revisión de los datos de entrenamiento y de la función de recompensas

Important

Estas son unas directrices generales. Defina sus propios umbrales en función de los requisitos empresariales, el rendimiento básico del modelo, las restricciones específicas del dominio y el análisis de la relación entre costo y beneficio del entrenamiento continuo.

Solución de problemas

Problemas comunes

Problema	Causa	Solución
Tiempo de espera de Lambda	Cálculo de recompensas complejo	Aumente el tiempo de espera de Lambda u optimice la función.
Permiso denegado	Faltan permisos de IAM:	Verifique que el rol de SageMaker puede invocar la función de Lambda.
Puntuaciones incoherentes	Función de recompensa no determinista	Utilice semillas fijas o lógica determinista.
Faltan resultados	Errores de Lambda no detectados	Agregue gestión integral de errores en Lambda.

Lista de comprobación de depuración

- Compruebe que los datos de entrada sigan el formato correcto con matrices de contenido anidadas.
- Confirme que el ARN de Lambda sea correcto y que la función esté implementada.
- Compruebe los permisos de IAM para la invocación de SageMaker → Lambda.
- Revise los registros de CloudWatch para detectar errores de Lambda.
- Valide que la respuesta de Lambda coincida con el formato esperado.

Prácticas recomendadas

- Comience de forma sencilla: comience con funciones de recompensas básicas e itere.
- Pruebe Lambda por separado: utilice los eventos de prueba de Lambda antes de la evaluación completa.
- Valide en un conjunto de datos pequeño: ejecute la evaluación en el subconjunto antes que en el conjunto de datos completo.

- Control de versiones: haga un seguimiento de las versiones de las funciones de recompensas junto con las versiones del modelo.
- Supervise los costos: las invocaciones de Lambda y el tiempo de computación afectan a los costos.
- Registre exhaustivamente: utilice instrucciones de impresión en Lambda para la depuración.
- Establezca los tiempos de espera de forma adecuada: equilibre la paciencia y el costo.
- Documente las métricas: defina claramente lo que mide cada métrica.

Siguientes pasos

Después de completar la evaluación del RFT:

- Si los resultados son satisfactorios: implemente el modelo en producción.
- Si es necesaria una mejora:
 - Ajuste la función de recompensas.
 - Recopile más datos de entrenamiento.
 - Modifique los hiperparámetros de entrenamiento.
 - Ejecute iteraciones de entrenamiento RFT adicionales.
- Supervisión continua: reevalúe periódicamente con nuevos datos.

Implementación de funciones de recompensas

Descripción general

La función de recompensas (también llamada puntuador o calificador) es el componente principal que evalúa las respuestas del modelo y proporciona señales de comentarios para el entrenamiento. Debe implementarse como una función de Lambda que acepte las respuestas del modelo y devuelva las puntuaciones de recompensas.

Formato de la interfaz

La función de recompensas debe aceptar y devolver datos en el formato siguiente:

Ejemplo de entrada para el entrenamiento

```
{  
  "messages": [  
    {  
      "text": "Hello, world!"  
    },  
    {  
      "text": "Goodbye, world!"  
    }  
  ]  
}
```



```

    {
        "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..."
    }
}

```

Ejemplo de carga útil para la función de Lambda de recompensas

El contenedor transforma automáticamente los datos antes de enviarlos a la función de Lambda de la siguiente manera:

1. Genera una respuesta del modelo para cada petición.
2. Anexa el turno del asistente (respuesta generada) a la matriz de mensajes.
3. Agrega un campo `id` único para el seguimiento.

La función de Lambda recibirá datos en este 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 Lambda de recompensas

```
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 y salida

Campos de entrada

Campo	Descripción	Notas adicionales
id	Identificador único para la muestra	Se vuelve a reflejar en la salida. Formato de la cadena
Mensajes	Historial de chat ordenado en formato OpenAI	Matriz de objetos de mensaje
messages[].role	Hablante del mensaje	Valores comunes: “usuario”, “asistente”, “sistema”
messages[].content	Contenido del texto del mensaje	Cadena sin formato
**metadatos	Información en formato libre para facilitar la calificación	Objeto; campos opcionales transferidos de los datos de entrenamiento

Campos de salida

Campo	Descripción	Notas adicionales
id	El mismo identificador que en la muestra de entrada	Debe coincidir con la entrada
aggregate_reward_score	Puntuación general de la muestra	Flotante (por ejemplo, entre 0,0 y 1,0 o un rango definido por la tarea)
metrics_list	Puntuaciones de los componentes que forman el agregado	Matriz de objetos métricos

Restricciones técnicas

- Límite de tiempo de espera: dispone de 15 minutos de tiempo máximo de ejecución por invocación a Lambda.
- Simultaneidad: debe gestionar solicitudes simultáneas de `rollout_worker_replicas * 64`.
- Fiabilidad: debe implementar una gestión de errores adecuada y devolver puntuaciones válidas de manera coherente.
- Rendimiento: optimice para una ejecución rápida (segundos, no minutos) que permita un entrenamiento eficiente.

Prácticas recomendadas

- Minimice las llamadas a la API externa.
- Utilice algoritmos y estructuras de datos eficientes.
- Implemente una lógica de reintento para los errores transitorios.
- Almacene en la memoria caché los cálculos reutilizables.
- Lleve a cabo pruebas exhaustivas antes del entrenamiento para garantizar una ejecución sin errores.

Uso de funciones de recompensas personalizadas

Implemente funciones de recompensas personalizadas cuando tenga criterios de evaluación específicos para cada tarea:

- Defina los criterios de evaluación: determine qué es lo que constituye una buena respuesta para su tarea.
- Implemente la función de Lambda: cree una función de Lambda según el formato de interfaz.
- Pruebe localmente: valide que la función devuelva las puntuaciones correctas para las entradas de muestra.
- Implemente en AWS: implemente la función de Lambda y anote el ARN.
- Configure la fórmula: agregue el ARN de Lambda al campo de `reward_lambda_arn` de la fórmula
- Lleve a cabo pruebas con un conjunto de datos pequeño: ejecute el RFT con un mínimo de datos para verificar la integración.

Permisos de IAM

Permisos necesarios

El rol de ejecución de SageMaker debe tener permisos para invocar la función de Lambda. Agregue esta política al rol de ejecución de SageMaker:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "lambda:InvokeFunction"
      ],
      "Resource": "arn:aws:lambda:region:account-id:function:function-name"
    }
  ]
}
```

Rol de ejecución de Lambda

El rol de ejecución de una función de Lambda necesita permisos de ejecución de Lambda básicos:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "logs:CreateLogGroup",
        "logs:CreateLogStream",
        "logs:PutLogEvents"
      ],
      "Resource": "arn:aws:logs:*:*:*"
    }
  ]
}
```

Permisos adicionales: si la función de Lambda accede a otros servicios de AWS (por ejemplo, S3 para los datos de referencia o DynamoDB para el registro), agregue esos permisos al rol de ejecución de Lambda.

Ejemplo: función de recompensas de LLM como juez

En este ejemplo, se muestra el uso de los modelos de Amazon Bedrock como jueces para evaluar las respuestas de los modelos al compararlas con las respuestas de referencia. Esta plantilla de Lambda proporciona un marco para que los clientes implementen llamadas a Amazon Bedrock para solicitudes de inferencia a fin de procesar las evaluaciones de los jueces. La función de Lambda mantiene el mismo contrato de entrada/salida que otras funciones de recompensas.

Implementación

Esta función de Lambda implementa un proceso de evaluación en dos etapas: `lambda_handler` extrae las respuestas del modelo y las respuestas de referencia de las muestras entrantes y, a continuación, la función `lambda_graded` llama a Amazon Bedrock para puntuar la similitud semántica entre ellas. La implementación incluye una sólida gestión de errores con reintentos automáticos para los errores transitorios y admite formatos de respuesta de referencia flexibles (tanto en formato de cadena como en formato de diccionario estructurado).

Detalles de la implementación:

- **Lógica de reintento:** implementa un retroceso exponencial (1, 2 o 4 segundos) para limitar las excepciones a fin de gestionar los límites de frecuencia de la API de Bedrock.
- **Gestión de errores:** devuelve una puntuación de 0,0 para las evaluaciones fallidas, en lugar de generar excepciones.
- **Puntuación determinista:** utiliza una temperatura igual a 0,0 para garantizar la coherencia de las puntuaciones en todas las evaluaciones.
- **Formato de referencia flexible:** gestiona automáticamente las respuestas de cadena y de referencia del diccionario.
- **Acotación de puntuaciones:** garantiza que todas las puntuaciones estén dentro de un rango válido [0,0, 1,0].
- **Independencia del modelo:** cambie `JUDGE_MODEL_ID` para usar cualquier modelo de 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
                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

La función de Lambda recibe el mismo formato de entrada que otras funciones de recompensas:

```

{
  "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 salida

```
{
  "id": "sample-001",
  "aggregate_reward_score": 0.85,
  "metrics_list": [
    {
      "name": "similarity_score",
      "value": 0.85,
      "type": "Metric"
    }
  ]
}
```

Consideraciones sobre la implementación

Es posible que también tenga que ajustar la plantilla de la petición y los parámetros de inferencia en función de las capacidades del modelo elegido y el formato de la API.

- Permisos de IAM: el rol de ejecución de Lambda debe tener el permiso `bedrock:InvokeModel` para el modelo elegido.
- Tiempo de espera: establezca el tiempo de espera de Lambda en al menos 60 segundos para adaptarse a la latencia y los reintentos de la API de Bedrock.
- Región: implemente en una región en la que esté disponible el modelo de Bedrock que haya elegido.
- Costo: supervise el uso de la API de Bedrock, ya que cada evaluación hace una llamada a la API por muestra.
- Rendimiento: para las evaluaciones a gran escala, solicite un aumento de las cuotas de Bedrock para evitar la limitación.

Aumento del rendimiento de Bedrock

Si experimenta limitaciones durante la evaluación, aumente las cuotas del modelo de Bedrock:

- Vaya a la consola de AWS Service Quotas.
- Busque “Bedrock” y seleccione la región.

- Busque la cuota para el modelo que haya elegido (por ejemplo, “Invocaciones por minuto para Claude 3.5 Sonnet”).
- Haga clic en “Solicitar aumento de cuota” y especifique el rendimiento deseado.
- Justifique el aumento (por ejemplo, “carga de trabajo de evaluación del RFT”).

La lógica de reintentos integrada de Lambda permite controlar las limitaciones ocasionales, pero las evaluaciones sostenidas de gran volumen requieren un aumento adecuado de las cuotas.

Política de IAM obligatoria:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "bedrock:InvokeModel"
      ],
      "Resource": "arn:aws:bedrock:*::foundation-model/*"
    }
  ]
}
```

Entrenamiento iterativo

El entrenamiento iterativo es un enfoque sistemático para refinar los modelos mediante varios ciclos de entrenamiento, en los que cada ronda se basa en el punto de control anterior y aborda las debilidades específicas detectadas en la evaluación. Este método permite introducir mejoras específicas en el rendimiento de los modelos mediante la incorporación de ejemplos seleccionados que abordan los modos de error, la adaptación a los requisitos cambiantes y la validación de las mejoras de forma gradual, en lugar de tener que llevar a cabo una sola sesión de entrenamiento de larga duración. Por lo general, el proceso sigue patrones como el refinamiento supervisado (SFT) seguido del RFT (refinamiento basado en recompensas), con puntos de control almacenados en buckets de S3 de custodia administrados por AWS a los que se puede hacer referencia en las siguientes iteraciones de entrenamiento, todo esto usando el mismo tipo de modelo y técnica de entrenamiento para no perder la coherencia a lo largo del proceso.

Para obtener más detalles, consulte [???](#).

Personalización de Amazon Nova en SageMaker HyperPod

Puede personalizar los modelos de Amazon Nova, incluidos los modelos de Amazon Nova 2.0 mejorados, con las [fórmulas de Amazon Nova](#) y entrenarlos en HyperPod. Una fórmula es un archivo de configuración YAML que proporciona detalles a SageMaker AI sobre cómo ejecutar el trabajo de personalización de modelos. SageMaker HyperPod admite dos tipos de servicios: Forge y no Forge.

HyperPod ofrece computación de alto rendimiento con instancias de GPU optimizadas y almacenamiento en Amazon FSx para Lustre, supervisión sólida mediante integración con herramientas como TensorBoard, administración flexible de puntos de control para mejorar las iteraciones, implementación fluida en Amazon Bedrock para tareas de inferencia y entrenamiento distribuido eficiente y escalable de varios nodos. Todo esto funciona de manera conjunta para brindar a las organizaciones un entorno seguro, eficaz y flexible en el que puedan adaptar los modelos de Amazon Nova a sus requisitos empresariales específicos.

La personalización de Amazon Nova en SageMaker HyperPod almacena los artefactos del modelo, como los puntos de control del modelo, en un bucket de Amazon S3 administrado por el servicio. Los artefactos del bucket administrado por el servicio se cifran con claves de AWS KMS administradas por SageMaker AI. Los buckets de Amazon S3 administrados por servicios no son compatibles actualmente con el cifrado de datos utilizando claves administradas por el cliente. Puede usar esta ubicación de punto de control para trabajos de evaluación o inferencias de Amazon Bedrock.

Se pueden aplicar precios estándar a instancias de cómputo, almacenamiento de Amazon S3 y FSx para Lustre. Para obtener información detallada sobre los precios, consulte [HyperPod pricing](#), [Precios de Amazon S3](#) y [Precios de Amazon FSx para Lustre](#).

Requisitos de computación de los modelos de Amazon Nova 2

En las siguientes tablas, se resumen los requisitos de computación de los trabajos de entrenamiento de SageMaker HyperPod y SageMaker AI para los modelos de Amazon Nova 2.

Requisitos de entrenamiento de Nova 2

Técnica de entrenamiento	Instancias mínimas	Tipo de instancia	Recuento de GPU	Notas	Modelos compatibles
SFT (LoRA)	4	P5.48xlarge	16	Refinamiento eficiente de parámetros	Nova 2 Lite
SFT (rango completo)	4	P5.48xlarge	32	Refinamiento de modelos completo	Nova 2 Lite
RFT en trabajos de entrenamiento de SageMaker (LoRA)	2	P5.48xlarge	16	Funciones de recompensas personalizadas en su entorno de AWS	Nova 2 Lite
RFT en trabajos de entrenamiento de SageMaker (rango completo)	4	P5.48xlarge	32	Longitud del contexto: 32 000	Nova 2 Lite
RFT en SageMaker HyperPod	8	P5.48xlarge	64	Longitud del contexto predeterminada: 8192	Nova 2 Lite
CPT	4	P5.48xlarge	16	Procesamiento de aproximadamente 400 millones	Nova 2 Lite

Técnica de entrenamiento	Instancias mínimas	Tipo de instancia	Recuento de GPU	Notas	Modelos compatibles
				de tokens por instancia al día	

Para optimizar los flujos de trabajo de personalización de modelos de Amazon Nova en Hyperpod, siga estas prácticas recomendadas para un entrenamiento eficiente, la administración de recursos y una implementación exitosa del modelo.

Prácticas recomendadas para la personalización de Amazon Nova

Descripción general

Esta sección proporciona información general sobre las técnicas de personalización y le permite elegir el mejor enfoque para sus necesidades y los datos disponibles.

Dos fases del entrenamiento de LLM

El entrenamiento de modelos de lenguaje de gran tamaño consta de dos fases principales: el entrenamiento previo y el posterior. Durante el entrenamiento previo, el modelo procesa fragmentos de texto sin procesar y los optimiza para la predicción del siguiente token. Este proceso crea un completador de patrones que absorbe la sintaxis, la semántica, los hechos y los patrones de razonamiento de la web y del texto seleccionado. Sin embargo, el modelo entrenado previamente no comprende las instrucciones, los objetivos del usuario ni el comportamiento adecuado para el contexto. Continúa el texto en cualquier estilo que se adapte a la distribución del entrenamiento. Un modelo entrenado previamente completa automáticamente en lugar de seguir las instrucciones, produce un formato incoherente y puede reflejar sesgos no deseados o contenido inseguro de los datos de entrenamiento. El entrenamiento previo desarrolla la competencia general, no la utilidad de las tareas.

El entrenamiento posterior transforma al completador de patrones en un asistente útil. Se llevan a cabo varias rondas de refinamiento supervisado (SFT) para enseñar al modelo a seguir las instrucciones, cumplir con los esquemas y las políticas, llamar a herramientas y producir salidas fiables mediante la imitación de demostraciones de alta calidad. Esta alineación enseña al modelo a responder a las peticiones como tareas en lugar de responder como texto para continuar. A

continuación, se aplica el refinamiento por refuerzo (RFT) para optimizar el comportamiento mediante comentarios medible (por ejemplo, verificadores o un LLM como juez), lo que equilibra las ventajas y desventajas, como la precisión frente a la brevedad, la seguridad frente a la cobertura, o el razonamiento en varios pasos bajo restricciones. En la práctica, se alternan el SFT y el RFT en ciclos para convertir el modelo entrenado previamente en un sistema fiable y alineado con las políticas que lleva a cabo tareas complejas de forma coherente.

Elección del enfoque de personalización correcto

En esta sección, trataremos las estrategias de personalización del entrenamiento posterior: RFT y SFT.

Refinamiento por refuerzo (RFT)

El refinamiento por refuerzo mejora el rendimiento del modelo mediante señales de comentarios (puntuaciones medibles o recompensas que indican la calidad de la respuesta) en lugar de una supervisión directa con respuestas exactas y correctas. A diferencia del refinamiento supervisado tradicional, que aprende de los pares de entradas y salidas, el RFT utiliza funciones de recompensas para evaluar las respuestas del modelo y lo optimiza de forma iterativa para maximizar estas recompensas. Este enfoque funciona bien para tareas en las que es difícil definir la salida exacta correcta, pero le permite medir de forma fiable la calidad de la respuesta. El RFT permite a los modelos aprender comportamientos y preferencias complejos mediante pruebas y comentarios, lo que lo hace ideal para aplicaciones que requieren una toma de decisiones matizada, una resolución de problemas creativa o el cumplimiento de criterios de calidad específicos que se puedan evaluar mediante programación. Por ejemplo, responder a preguntas legales complejas es un caso de uso ideal para el RFT, ya que se quiere enseñar al modelo a razonar mejor para responder a las preguntas con mayor precisión.

Funcionamiento

En el refinamiento por refuerzo, se parte de una línea de base ajustada a las instrucciones y se trata cada petición como si fuera un pequeño torneo. Para una entrada determinada, se toman muestras de varias respuestas candidatas del modelo, se puntúa cada una con la función de recompensa y, a continuación, se clasifican dentro de ese grupo. El paso de actualización empuja al modelo a hacer que los candidatos con mayor puntuación tengan más probabilidades la próxima vez y que los que obtengan puntuaciones más bajas sean menos probables, mientras que la restricción de mantenerse cerca de la línea de base evita que el comportamiento se desvíe o se vuelva detallado o explotador. Este ciclo se repite a lo largo de muchas peticiones, se actualizan los casos difíciles, se

endurecen los verificadores o se juzgan las rúbricas cuando se detectan vulnerabilidades y se hace un seguimiento continuo de las métricas de las tareas.

Cuándo se debe usar el RFT

Las tareas que más se benefician del RFT comparten varias características. Tienen señales de éxito cuantificables incluso cuando es difícil especificar una única salida correcta. Admiten un crédito parcial o una calificación de calidad, por lo que puede clasificar las mejores respuestas frente a las peores dentro de una petición o mediante una función de recompensa. Implican varios objetivos que deben equilibrarse (como la precisión con la brevedad, la claridad, la seguridad o el costo). Exigen el cumplimiento de restricciones explícitas que se pueden comprobar mediante programación. Funcionan en entornos mediados por herramientas o basados en el entorno en los que los resultados son observables (éxito o error, latencia, uso de recursos). Ocurren en regímenes con pocas etiquetas, en los que la recolección de objetivos de oro es cara, pero los comentarios automatizados o basados en rúbricas es abundante. El RFT funciona mejor cuando se puede convertir la calidad en un valor escalar o una clasificación fiable y se quiere que el modelo amplifique de forma preferencial los comportamientos con puntuaciones más altas sin necesidad de etiquetar objetivos de forma exhaustiva.

Considere el uso de otros métodos cuando:

- Tenga pares de entrada-salida etiquetados abundantes y fiables: utilice el SFT.
- La principal brecha sea el conocimiento o la jerga: utilice la generación aumentada por recuperación (RAG)
- La señal de recompensa sea ruidosa o poco fiable y no pueda corregirla con mejores rúbricas o comprobadores: estabilícela antes del RFT

Cuándo no utilizar el RFT

Evite el RFT en las siguientes situaciones:

- Puede producir pares de entrada-salida etiquetados y fiables de forma económica (el SFT es más sencillo, económico y estable).
- La brecha es el conocimiento o la jerga y no el comportamiento (utilice la RAG).
- La señal de recompensa es ruidosa, dispersa, fácil de manipular, cara o lenta de calcular (corrija antes el evaluador).
- El rendimiento de la línea de base es casi nulo (arranque con el SFT antes de optimizar las preferencias).

- La tarea tiene esquemas deterministas, un formato estricto o una única respuesta correcta (el SFT o la validación basada en reglas funcionan mejor).
- Los presupuestos ajustados de latencia o costos no pueden absorber el muestreo o la exploración adicionales que requiere el RFT.
- Las restricciones de seguridad o políticas no se especifican con precisión ni se pueden aplicar en la recompensa.

Si puede apuntar a “la respuesta correcta”, utilice el SFT. Si necesita nuevos conocimientos, utilice la RAG. Utilice el RFT solo después de tener una línea de base sólida y una función de recompensa robusta, rápida y difícil de explotar.

Refinamiento supervisado (SFT)

El refinamiento supervisado entrena al LLM con un conjunto de datos de pares de entrada-salida etiquetados por humanos para la tarea. Se proporcionan ejemplos de peticiones (preguntas, instrucciones, etc.) junto con las respuestas correctas o deseadas y se continúa entrenando al modelo con estos ejemplos. El modelo ajusta las ponderaciones para minimizar una pérdida supervisada (suele ser una entropía cruzada entre sus predicciones y los tokens de respuesta objetivo). Es el mismo entrenamiento que se utiliza en la mayoría de las tareas de machine learning supervisadas, que se aplica para especializar un LLM.

El SFT cambia el comportamiento, no el conocimiento. No enseña al modelo nuevos hechos o jerga que no haya visto en el entrenamiento previo. Enseña al modelo cómo responder, no qué saber. Si necesita nuevos conocimientos de dominio (como la terminología interna), utilice la generación aumentada por recuperación (RAG) para proporcionar ese contexto en el momento de la inferencia. A continuación, el SFT agrega el comportamiento de seguimiento de instrucciones deseado en la parte superior.

Funcionamiento

El SFT optimiza el LLM al minimizar la pérdida media de entropía cruzada en los tokens de respuesta, tratar los tokens de petición como contexto y ocultarlos de la pérdida. El modelo internaliza el estilo, la estructura y las reglas de decisión del objetivo, y aprende a generar la forma correcta de completar cada petición. Por ejemplo, para clasificar los documentos en categorías personalizadas, se refina el modelo con peticiones (el texto del documento) y terminaciones etiquetadas (las etiquetas de las categorías). Se entrena con esos pares hasta que el modelo muestre la etiqueta correcta para cada petición con una probabilidad alta.

Puede llevar a cabo el SFT con tan solo unos cientos de ejemplos y escalarlo hasta unos cientos de miles. Las muestras del SFT deben ser de alta calidad y estar directamente alineadas con el comportamiento deseado del modelo.

Cuándo usar el SFT

Utilice el SFT cuando tenga una tarea bien definida con las salidas deseadas claras. Si puede decir explícitamente “Con una entrada X, la salida correcta es Y” y puede recopilar ejemplos de este tipo de asignaciones, el refinamiento supervisado es una buena opción. El SFT sobresale en los siguientes escenarios:

- Tareas de clasificación estructuradas o complejas: clasifique documentos internos o contratos en muchas categorías personalizadas. Con el SFT, el modelo aprende estas categorías específicas mejor que con peticiones por sí solas.
- Tareas de respuesta a preguntas o de transformación con respuestas conocidas: refine un modelo para que responda a preguntas de la base de conocimientos de una empresa o convierta datos de un formato a otro, en el que cada entrada tenga una respuesta correcta.
- Formato y estilo coherentes: entrene al modelo para que responda siempre en un formato o tono determinado mediante el refinamiento de los ejemplos del formato o tono correctos. Por ejemplo, si se entrena con pares de petición-respuesta que reflejan la voz de una marca concreta, se puede enseñar al modelo a generar salidas con ese estilo. El comportamiento de seguimiento de instrucciones suele enseñarse inicialmente mediante el SFT con ejemplos seleccionados que demuestran cómo debe comportarse un buen asistente.

El SFT es la forma más directa de enseñarle a un LLM una nueva habilidad o comportamiento cuando se puede especificar cuál es el comportamiento correcto. Utiliza la comprensión lingüística existente del modelo y la centra en la tarea. Utilice el SFT cuando desee que el modelo haga algo específico y tenga o pueda crear un conjunto de datos de ejemplos.

Utilice el SFT cuando pueda reunir pares de peticiones y respuestas de alta calidad que reflejen fielmente el comportamiento deseado. Encaja con tareas con objetivos claros o formatos deterministas, como esquemas, llamadas de funciones o herramientas y respuestas estructuradas en las que la imitación es una señal de entrenamiento adecuada. El objetivo es moldear el comportamiento: enseñar al modelo a tratar las peticiones como tareas, seguir instrucciones, adoptar políticas de tono y rechazo y producir un formato coherente. Planifique al menos cientos de demostraciones en las que la calidad, la coherencia y la deduplicación de datos sean más importantes que el volumen bruto. Para llevar a cabo una actualización sencilla y rentable, utilice

métodos eficientes en cuanto a parámetros, como la adaptación de rango bajo, para entrenar adaptadores pequeños mientras deja intacta la mayor parte de la estructura básica.

Cuándo no utilizar el SFT

No utilice el SFT cuando la brecha se deba al conocimiento y no al comportamiento. No enseña al modelo nuevos hechos, jerga ni eventos recientes. En esos casos, utilice la generación aumentada por recuperación para llevar conocimiento externo a la inferencia. Evite el SFT cuando pueda medir la calidad, pero no pueda etiquetar una sola respuesta correcta. Utilice el refinamiento por refuerzo con recompensas verificables o con un LLM como juez para optimizar esas recompensas directamente. Si sus necesidades o su contenido cambian con frecuencia, confíe en la recuperación y el uso de las herramientas en lugar de volver a entrenar el modelo.

Temas

- [SDK de Nova Forge](#)
- [Creación de un clúster de EKS de SageMaker HyperPod con un grupo de instancias restringido \(RIG\)](#)
- [Guía de comandos esenciales de Amazon SageMaker HyperPod](#)
- [Acceso a Nova Forge y configuración](#)
- [Entrenamiento de los modelos de Amazon Nova](#)
- [Evaluación del modelo entrenado](#)
- [Supervisión de los trabajos de HyperPod con MLFlow](#)

SDK de Nova Forge

El SDK de Amazon Nova Forge es un SDK de Python completo que proporciona una interfaz programática unificada para todo el ciclo de vida de personalización de modelos de Amazon Nova. El SDK simplifica la personalización de los modelos gracias a una API única y coherente para entrenar, evaluar, supervisar, implementar y realizar inferencias en las plataformas de Amazon SageMaker y Amazon Bedrock.

Para obtener más información, consulte [SDK de Nova Forge](#).

Creación de un clúster de EKS de SageMaker HyperPod con un grupo de instancias restringido (RIG)

Para personalizar un modelo en HyperPod, se debe configurar la infraestructura necesaria. Para obtener más información sobre la configuración de un clúster de EKS de SageMaker HyperPod con un grupo de instancias restringido (RIG), consulte el [taller](#), que proporciona un recorrido detallado del proceso de configuración.

Guía de comandos esenciales de Amazon SageMaker HyperPod

Amazon SageMaker HyperPod dispone de muchas herramientas de línea de comandos para administrar los flujos de trabajo de entrenamiento. En esta guía se describen los comandos esenciales para las operaciones habituales, desde la conexión al clúster hasta la supervisión del progreso del trabajo.

Requisitos previos

Antes de usar estos comandos, asegúrese de haber realizado la siguiente configuración:

- Clúster de SageMaker HyperPod creado con RIG (normalmente en us-east-1)
- Bucket de Amazon S3 de salida creado para artefactos de entrenamiento
- Roles de IAM con los permisos adecuados
- Datos de entrenamiento cargados en el formato JSONL correcto
- Sincronización con FSx para Lustre completada (compruébelo en los registros del clúster en el primer trabajo)

Temas

- [Instalación de la CLI de la fórmula](#)
- [Conexión al clúster](#)
- [Inicio de un trabajo de entrenamiento](#)
- [Seguimiento del estado del trabajo](#)
- [Supervisión de los registros de trabajo](#)
- [Listado de los trabajos activos](#)
- [Cancelar una tarea](#)

- [Puesta en marcha de un trabajo de evaluación](#)
- [Problemas comunes](#)

Instalación de la CLI de la fórmula

Desplácese hasta la raíz del repositorio de fórmulas antes de usar el comando de instalación.

Utilice el repositorio de fórmulas de HyperPod si utiliza técnicas de personalización que no sean de Forge. Para la personalización basada en Forge, consulte el repositorio de fórmulas específico de Forge.

Use los siguientes comandos para instalar la CLI de SageMaker HyperPod:

Note

Asegúrese de no estar en un entorno conda, anaconda o miniconda activo o en algún otro entorno virtual

Si es así, salga del entorno mediante:

- `conda deactivate` para entornos conda, anaconda o miniconda
- `deactivate` para entornos virtuales de Python

Si está utilizando una técnica de personalización que no sea de Forge, descargue las fórmulas de `sagemaker-hyperpod` como se muestra a continuación:

```
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
```

Si cuenta con una suscripción a Forge, debería poder descargar las fórmulas mediante el proceso mencionado a continuación.

```
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 un [nuevo entorno virtual](#) antes de poner en marcha `pip install -e .`, use:

- `python -m venv nova_forge`
- `source nova_forge/bin/activate`
- La línea de comandos ahora mostrará (nova_forge) al principio de la petición.
- Esto garantiza que las dependencias no compitan cuando se use la CLI.

Propósito: ¿por qué usamos `pip install -e .`?

Este comando instala la CLI de SageMaker HyperPod en modo editable, lo que le permite utilizar fórmulas actualizadas sin tener que volver a instalarlas cada vez que quiera usarlas. También le permite agregar nuevas fórmulas que la CLI puede usar automáticamente.

Conexión al clúster

Conecte la CLI de SageMaker HyperPod a su clúster antes de llevar a cabo cualquier trabajo:

```
export AWS_REGION=us-east-1 && SageMaker HyperPod connect-cluster --cluster-name
<your-cluster-name> --region us-east-1
```

 Important

Este comando crea un archivo de contexto (/tmp/hyperpod_context.json) necesario para los comandos que se usarán a continuación. Si ve un error indicando que no se puede encontrar el archivo, vuelva a usar el comando connect.

Consejo profesional: si quiere configurar el clúster para que utilice siempre el espacio de nombres kubeflow, agregue el argumento `--namespace kubeflow` al comando de la siguiente manera:

```
export AWS_REGION=us-east-1 && \  
hyperpod connect-cluster \  
--cluster-name <your-cluster-name> \  
--region us-east-1 \  
--namespace kubeflow
```

De esta forma no tendrá que agregar `-n kubeflow` en todos los comandos al interactuar con sus tareas.

Inicio de un trabajo de entrenamiento

 Note

Si lleva a cabo trabajos de PPO o RFT, asegúrese de agregar los ajustes del selector de etiquetas para `src/hyperpod_cli/sagemaker_hyperpod_recipes/recipes_collection/cluster/k8s.yaml` de forma que todos los pods estén programados en el mismo nodo.

```
label_selector:  
  required:  
    sagemaker.amazonaws.com/instance-group-name:  
      - <rig_group>
```

Lanzamiento de un trabajo de entrenamiento mediante una fórmula con modificaciones de parámetros opcionales:

```
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"
}'
```

Resultado previsto:

```
Final command: python3 <path_to_your_installation>/NovaForgeHyperpodCLI/src/
hyperpod_cli/sagemaker_hyperpod_recipes/main.py recipes=fine-tuning/nova/
nova_micro_p5_gpu_sft cluster_type=k8s cluster=k8s base_results_dir=/local/home/
<username>/results cluster.pullPolicy="IfNotPresent" cluster.restartPolicy="OnFailure"
  cluster.namespace="kubeflow" container="708977205387.dkr.ecr.us-east-1.amazonaws.com/
nova-fine-tune-repo:HP-SFT-DATAMIX-latest"
```

```
Prepared output directory at /local/home/<username>/results/<job-name>/k8s_templates
Found credentials in shared credentials file: ~/.aws/credentials
Helm script created at /local/home/<username>/results/<job-name>/<job-name>_launch.sh
Running Helm script: /local/home/<username>/results/<job-name>/<job-name>_launch.sh
```

```
NAME: <job-name>
LAST DEPLOYED: Mon Sep 15 20:56:50 2025
NAMESPACE: kubeflow
STATUS: deployed
REVISION: 1
TEST SUITE: None
Launcher successfully generated: <path_to_your_installation>/NovaForgeHyperpodCLI/src/
hyperpod_cli/sagemaker_hyperpod_recipes/launcher/nova/k8s_templates/SFT

{
  "Console URL": "https://us-east-1.console.aws.amazon.com/sagemaker/home?region=us-
east-1#/cluster-management/<your-cluster-name>"
}
```

Seguimiento del estado del trabajo

Supervise los trabajos en marcha con kubectl:

```
kubectl get pods -o wide -w -n kubeflow | (head -n1 ; grep <your-job-name>)
```

Explicación de los estados de los pods

En la siguiente tabla se explican los estados comunes de los pods:

Estado	Descripción
Pending	Se acepta el pod, pero aún no se ha programado o en un nodo o se está esperando a que se extraigan las imágenes del contenedor
Running	El pod está enlazado a un nodo con al menos un contenedor en marcha o iniciándose.
Succeeded	Todos los contenedores se completaron correctamente y no se reiniciarán.
Failed	Todos los contenedores terminaron con al menos uno de ellos devolviendo un error.
Unknown	No se puede determinar el estado del pod (normalmente debido a problemas de comunicación entre los nodos).
CrashLoopBackOff	El contenedor falla repetidamente; Kubernetes se retrasa ante los intentos de reinicio.
ImagePullBackOff / ErrImagePull	No se pudo extraer la imagen del contenedor del registro.
OOMKilled	El contenedor se canceló por superar los límites de memoria.
Completed	El trabajo o el pod finalizaron correctamente (finalización del trabajo por lotes).

 Tip

Use el indicador `-w` para ver las actualizaciones del estado del pod en tiempo real. Pulse `Ctrl+C` para dejar de ver.

Supervisión de los registros de trabajo

Puede ver los registros de tres maneras:

Uso de CloudWatch

Los registros están disponibles en la cuenta de AWS que contiene el clúster de HyperPod en CloudWatch. Para verlos en su navegador, vaya a la página de inicio de CloudWatch en su cuenta y busque el nombre del clúster. Por ejemplo, si su clúster se llamara `my-hyperpod-rig`, el grupo de registro tendría el prefijo:

- Grupo de registro: `/aws/sagemaker/Clusters/my-hyperpod-rig/{UUID}`
- Una vez en el grupo de registro, podrá encontrar el registro específico mediante el ID de la instancia del nodo, como `-hyperpod-i-00b3d8a1bf25714e4`.
 - `i-00b3d8a1bf25714e4` aquí representa el nombre de la máquina compatible con HyperPod en la que se está poniendo en marcha el trabajo de entrenamiento. Recuerde que en el resultado del comando `kubectl get pods -o wide -w -n kubeflow | (head -n1 ; grep my-cpt-run)` anterior capturamos una columna llamada `NODE`.
 - En este caso, el nodo maestro se ponía en marcha en `hyperpod-i-00b3d8a1bf25714e4` y, por lo tanto, utilizaremos esa cadena para seleccionar el grupo de registro que queremos ver. Seleccione el que dice `SageMakerHyperPodTrainingJob/rig-group/[NODE]`.

Uso de Información de CloudWatch

Si tiene a mano el nombre de su trabajo y no desea seguir todos los pasos anteriores, simplemente consulte todos los registros en `/aws/sagemaker/Clusters/my-hyperpod-rig/{UUID}` para encontrar el registro individual.

CPT:

```
fields @timestamp, @message, @logStream, @log
| filter @message like /(?!Starting CPT Job/
| sort @timestamp desc
| limit 100
```

Para completar el trabajo, sustituya `Starting CPT Job` por `CPT Job completed`.

Luego, puede hacer clic en los resultados y elegir el que diga “Epoch 0”, ya que ese será el nodo maestro.

Uso de AWS CLI

Puede optar por rastrear los registros mediante AWS CLI. Antes de hacerlo, compruebe su versión de AWS CLI utilizando `aws --version`. También se recomienda usar este script de utilidad que ayuda a rastrear los registros en tiempo real en su 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
```

Listado de los trabajos activos

Vea todos los trabajos que están en marcha en el clúster:

```
hyperpod list-jobs -n kubeflow
```

Ejemplo de código de salida:

```
{
  "jobs": [
    {
      "Name": "test-run-nhgza",
      "Namespace": "kubeflow",
      "CreationTime": "2025-10-29T16:50:57Z",
      "State": "Running"
    }
  ]
}
```

Cancelar una tarea

Detenga el trabajo en marcha en cualquier momento:

```
hyperpod cancel-job --job-name <job-name> -n kubeflow
```

Búsqueda del nombre del trabajo

Opción 1: a partir de una fórmula

El nombre del trabajo se especifica en el bloque `run` de la fórmula:

```
run:
  name: "my-test-run"                # This is your job name
  model_type: "amazon.nova-micro-v1:0:128k"
  ...
```

Opción 2: a partir del comando `list-jobs`

Use `hyperpod list-jobs -n kubeflow` y copie el campo `Name` de la salida.

Puesta en marcha de un trabajo de evaluación

Evalúe un modelo entrenado o un modelo base mediante una fórmula de evaluación.

Requisitos previos

Antes de poner en marcha trabajos de evaluación, asegúrese de que dispone de lo siguiente:

- URI del punto de control de Amazon S3 del archivo `manifest.json` de su trabajo de entrenamiento (para modelos entrenados)
- Conjunto de datos de evaluación cargado en Amazon S3 en el formato correcto
- Ruta de Amazon S3 para ver los resultados de la evaluación

Comando

Use el siguiente comando para iniciar un trabajo de evaluación:

```
hyperpod start-job -n kubeflow \
  --recipe evaluation/nova/nova_2_0/nova_lite/
nova_lite_2_0_p5_48x1_gpu_bring_your_own_dataset_eval \
  --override-parameters '{
    "instance_type": "p5.48xlarge",
    "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-
HP-Eval-latest",
```

```
"recipes.run.name": "<your-eval-job-name>",
"recipes.run.model_name_or_path": "<checkpoint-s3-uri>",
"recipes.run.output_s3_path": "s3://<your-bucket>/eval-results/",
"recipes.run.data_s3_path": "s3://<your-bucket>/eval-data.jsonl"
}'
```

Descripciones de los parámetros:

- `recipes.run.name`: nombre único del trabajo de evaluación
- `recipes.run.model_name_or_path`: URI de Amazon S3 de `manifest.json` o de la ruta del modelo base (por ejemplo, `nova-micro/prod`)
- `recipes.run.output_s3_path`: ubicación de Amazon S3 para los resultados de la evaluación
- `recipes.run.data_s3_path`: ubicación en Amazon S3 del conjunto de datos de evaluación

Consejos:

- Fórmulas específicas para cada modelo: cada tamaño de modelo (`micro`, `lite`, `pro`) tiene su propia fórmula de evaluación.
- Evaluación del modelo base: utilice las rutas del modelo base (por ejemplo, `nova-micro/prod`) en lugar de los URI de puntos de control para evaluar los modelos base.

Formato de los datos de evaluación

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 salida:

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

Descripción de campos:

- **prompt:** entrada formateada enviada al modelo
- **inference:** respuesta generada por el modelo
- **gold:** respuesta correcta esperada del conjunto de datos de entrada
- **metadata:** metadatos opcionales transferidos desde la entrada

Problemas comunes

- **ModuleNotFoundError:** No module named 'nemo_launcher', puede que tenga que agregar `nemo_launcher` a su ruta de Python en función del lugar donde se haya instalado `hyperpod_cli`. Comando de ejemplo

```
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 no puso en marcha el comando `hyperpod connect cluster`.
- Si no ve el trabajo programado, compruebe si la salida de la CLI de SageMaker HyperPod incluye esta sección con los nombres de los trabajos y otros metadatos. Si no es así, vuelva a instalar el gráfico de Helm usando:

```
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
```

Acceso a Nova Forge y configuración

Para configurar Amazon Nova Forge para su uso en los trabajos, debe hacer lo siguiente:

- [Suscribirse a Amazon Nova Forge](#)
- [Configurar un clúster](#)

Temas

- [Suscribirse a Amazon Nova Forge](#)
- [Configuración de la infraestructura](#)
- [IA responsable](#)

Suscribirse a Amazon Nova Forge

Para acceder a las características de Amazon Nova Forge, siga los pasos que se describen a continuación:

1. Verifique el acceso de administrador a la cuenta de AWS.
2. Vaya a la consola de SageMaker AI y [solicite acceso a Amazon Nova Forge](#).
3. Espere a que el equipo de Amazon Nova envíe una confirmación por correo electrónico una vez aprobada la solicitud de suscripción.
4. Etiquete el rol de puesta en marcha con la etiqueta `forge-subscription`. Esta etiqueta es necesaria para acceder a las características y puntos de control de Amazon Nova Forge. Agregue la siguiente etiqueta al rol de puesta en marcha:
 - Clave: `forge-subscription`
 - Valor: `true`

Note

Las características estándar de Amazon Nova siguen estando disponibles sin una suscripción a Forge. Amazon Nova Forge está diseñado para crear modelos de frontera personalizados con control y flexibilidad en todas las fases del entrenamiento del modelo.

Configuración de la infraestructura

Una vez aprobada su suscripción a Amazon Nova Forge, configure la infraestructura necesaria para utilizar las características habilitadas para Forge. Para obtener instrucciones detalladas sobre cómo crear un clúster de EKS con un grupo de instancias restringido (RIG), siga las [instrucciones del taller](#).

IA responsable

Configuración de moderación de contenido: los clientes de Amazon Nova Forge tienen acceso a la configuración de moderación de contenido personalizable (CCMS) para los modelos de Amazon Nova Lite 1.0 y Pro 1.0. La CCMS le permite ajustar los controles de moderación de contenido para adaptarlos a sus requisitos empresariales específicos y, al mismo tiempo, mantener las medidas de protección esenciales y específicas de la IA responsable. Para determinar si su caso de uso empresarial cumple los requisitos de la CCMS, póngase en contacto con su administrador de cuentas de Amazon Web Services.

Amazon Nova Forge proporciona un kit de herramientas de IA responsable que incluye datos de entrenamiento, pruebas comparativas de evaluación y controles de tiempo de ejecución para que sus modelos se adhieran a las directrices de IA responsable de Amazon Nova.

Datos de entrenamiento: la categoría “RAI” de mezcla de datos incluye casos y escenarios que hacen hincapié en los principios de la IA responsable, los aspectos importantes en materia de seguridad y la implementación responsable de tecnología. Úselos para adaptar sus modelos de forma responsable durante el entrenamiento previo continuo.

Evaluaciones: las tareas de prueba comparativa sirven para probar la capacidad de su modelo para detectar y rechazar contenido inapropiado, dañino o incorrecto. Utilice estas evaluaciones para medir la diferencia entre el rendimiento del modelo base y el rendimiento del modelo personalizado.

Entrenamiento de los modelos de Amazon Nova

El entrenamiento de los modelos de Amazon Nova en SageMaker HyperPod admite varias técnicas, como el entrenamiento previo continuo (CPT), el refinamiento supervisado (SFT) y el refinamiento por refuerzo (RFT). Cada técnica responde a diferentes necesidades de personalización y se puede aplicar a distintas versiones de modelos de Amazon Nova.

Temas

- [Entrenamiento previo continuo \(CPT\)](#)
- [Refinamiento supervisado \(SFT\)](#)

- [Refinamiento por refuerzo \(RFT\) en SageMaker HyperPod](#)

Entrenamiento previo continuo (CPT)

El entrenamiento previo continuo (CPT) es una técnica de entrenamiento que amplía la fase de entrenamiento previo de un modelo básico exponiéndolo a texto adicional sin etiquetar de dominios o corpus específicos. A diferencia del refinamiento supervisado, que requiere combinaciones de entradas y salidas etiquetadas, el CPT entrena con documentos sin procesar para ayudar al modelo a adquirir un conocimiento más profundo de nuevos dominios, aprender terminología y patrones de escritura específicos de cada dominio y adaptarse a tipos de contenido o áreas temáticas particulares.

Este enfoque es particularmente valioso cuando se tienen grandes volúmenes (decenas de miles de millones de tokens) de datos de texto específicos de un dominio, como documentos legales, bibliografía médica, documentación técnica o contenido empresarial patentado, y se desea que el modelo desarrolle una fluidez nativa en ese dominio. Por lo general, después de la fase de CPT, el modelo tiene que pasar por etapas adicionales de ajuste mediante instrucciones para poder utilizar el conocimiento recién adquirido y completar tareas útiles.

Modelos compatibles

El CPT está disponible para los siguientes modelos de Amazon Nova:

- Nova 1.0 (Micro, Lite, Pro)
- Nova 2.0 (Lite)

Cuándo se debe usar Nova 1.0 en lugar de Nova 2.0

La familia de modelos de Amazon Nova ofrece varios puntos operativos de relación entre precio y rendimiento para optimizar la precisión, la velocidad y el costo.

Elija Nova 2.0 cuando necesite lo siguiente:

- Capacidades de razonamiento avanzadas para tareas analíticas complejas
- Rendimiento superior en codificación, matemáticas y resolución de problemas científicos
- Soporte de mayor longitud de contexto
- Mejor rendimiento multilingüe

Note

El modelo más grande no siempre es mejor. Tenga en cuenta la relación costo-rendimiento y los requisitos específicos de su empresa cuando tenga que elegir entre los modelos de Nova 1.0 y Nova 2.0.

CPT en Nova 2.0

Amazon Nova Lite 2.0 es un modelo de razonamiento entrenado con un conjunto de datos más amplio y diverso que Amazon Nova Lite 1.0. A pesar de ser un modelo más grande, Nova Lite 2.0 ofrece inferencias más rápidas que Nova Lite 1.0 y, al mismo tiempo, ofrece capacidades de razonamiento mejoradas, contextos más extensos y un rendimiento multilingüe mejorado.

El CPT de Nova 2.0 le permite ampliar estas capacidades avanzadas con datos específicos del dominio, lo que permite al modelo desarrollar una amplia experiencia en áreas especializadas y, al mismo tiempo, mantener sus excelentes capacidades analíticas y de razonamiento.

Fórmula del CPT de muestra

A continuación se ofrece una fórmula de muestra para el CPT. Puedes encontrar esta fórmula y otras en el repositorio 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                            # Maximum context window size (tokens)
  global_batch_size: 256                      # Global batch size, allowed values are
32, 64, 128, 256.

  trainer:
    max_steps: 10                             # The number of training steps to run
total
    val_check_interval: 10                   # The number of steps between running
validation. Integer count or float percentage
    limit_val_batches: 2                     # Batches of the validation set to use
each trigger

  model:
    hidden_dropout: 0.0                      # Dropout for hidden states, must be
between 0.0 and 1.0
    attention_dropout: 0.0                  # Dropout for attention weights, must
be between 0.0 and 1.0

  optim:
    optimizer: adam
    lr: 1e-5                                 # Learning rate
    name: distributed_fused_adam            # Optimizer algorithm, do not change
    adam_w_mode: true                       # Enable AdamW mode
    eps: 1e-06                             # Epsilon for numerical stability
    weight_decay: 0.0                      # L2 regularization strength, must be
between 0.0 and 1.0
    adam_beta1: 0.9                        # Beta1 for Adam optimizer
    adam_beta2: 0.95                      # Beta2 for Adam optimizer
    sched:
      warmup_steps: 10                     # Learning rate warmup steps
      constant_steps: 0                    # Steps at constant learning rate
      min_lr: 1e-6                        # Minimum learning rate, must be lower
than lr

```

Preparación de datos para el CPT en 2.0

Requisitos del formato de los datos

Los conjuntos de datos de entrenamiento y validación deben ser archivos JSONL que siguen el formato que se muestra más abajo, donde cada línea contiene un objeto JSON que representa una conversación con la estructura y los campos requeridos. A continuación se muestra un ejemplo:

```
{"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"}
```

Las entradas de texto deben incluir contenido fluido y de alta calidad que represente el dominio de destino.

Compruebe que los datos se puedan convertir al [formato Arrow](#). Use el script de Python que aparece a continuación como ayuda. Asegúrese de utilizar como mínimo la versión `datasets==2.18.0`:

```
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)
```

Debe imprimir el mismo número de líneas que había en el archivo JSONL.

Cuando utilice la mezcla de datos, ejecute el primer trabajo con `max_steps=2`. Esto ayudará a crear optimizaciones en el clúster para el acceso a los datos y a validar que todas las mezclas de datos estén disponibles.

Cómo se preparan los datos para el CPT

Los datos de entrenamiento son el factor determinante más importante para el éxito del entrenamiento previo continuo. Si bien los datos del CPT suelen describirse como “no etiquetados”, la realidad es mucho más matizada. La forma en que se estructuran, formatean y presentan los datos

determina si el modelo adquirirá las habilidades y los conocimientos necesarios para el caso de uso empresarial.

Preparación de conjuntos de datos empresariales estructurados para el CPT

Este es un desafío común para las empresas y organizaciones que crean modelos básicos especializados en su dominio. La mayoría de las empresas poseen amplios repositorios de datos estructurados: catálogos de productos, perfiles de usuarios, registros de transacciones, envíos de formularios, llamadas a la API y metadatos operativos. A primera vista, su aspecto es muy diferente del texto web no estructurado que se suele utilizar en el entrenamiento previo estándar.

Para aprender eficazmente de los datos empresariales estructurados, piense detenidamente en las tareas descendentes y diseñe la presentación de los datos para obligar al modelo a aprender las relaciones predictivas correctas.

Para aprovechar todo el potencial del entrenamiento previo continuo, tenga en cuenta lo siguiente:

- Qué tareas debe llevar a cabo el modelo en el momento de la inferencia
- Qué información está presente en los datos sin procesar
- Cómo se estructuran los datos para que el modelo aprenda a extraer y manipular la información correctamente

El simple hecho de incluir datos estructurados en el entrenamiento no enseñará al modelo a razonar al respecto. Diseñe activamente la presentación de los datos para guiar lo que aprende el modelo.

En las siguientes secciones, se analiza la bibliografía que demuestra la importancia del aumento de datos y se proporcionan ejemplos de estrategias de ampliación de datos empresariales estructurados que aportarán ideas útiles sobre cómo tratar y organizar los conjuntos de datos empresariales para el CPT.

Datos estructurados para el CPT en la bibliografía

El CPT puede empaquetar hechos del dominio en el modelo, pero a menudo no logra que esos datos se puedan recuperar o manipular cuando cambian las entradas o las tareas. Los experimentos controlados muestran que, si no se efectúa un aumento de la diversidad durante el entrenamiento previo, los modelos memorizan datos de forma frágil y resulta difícil extraerlos incluso después de ajustar las instrucciones posteriormente, por lo que se recomienda inyectar las instrucciones en forma de señales al principio del entrenamiento. En el caso de los datos semiestructurados, la

serialización por asignación al azar y otros aumentos reducen el sobreajuste del esquema, razón por la cual el CPT debería intercalarse con tareas de tipo instructivo en lugar de ejecutarlas primero seguidas de IFT. Un trabajo centrado en las finanzas revela además que la combinación conjunta de los datos de instrucciones y el CPT en trabajos por lotes mejora la generalización y reduce el olvido en comparación con la fórmula secuencial. El informe técnico de Qwen sigue el mismo patrón al integrar datos de instrucciones de alta calidad en el propio entrenamiento previo, lo que impulsa el aprendizaje contextual y conserva el seguimiento de instrucciones mientras se adquieren nuevos conocimientos del dominio.

El aumento de datos para corpus semiestructurados es un factor clave. El CPT basado en grafos sintéticos amplía los conjuntos de dominios pequeños hasta convertirlos en corpus vinculados a entidades que enseñan de forma explícita las relaciones y los compuestos mediante la recuperación en el momento de la inferencia. El CPT conjunto, junto con la combinación de instrucciones, supera a las canalizaciones secuenciales en un dominio de finanzas, mientras que el equilibrio del dominio con los datos generales reduce la degradación de las habilidades generales. El CPT de dominio a gran escala también puede retener una amplia capacidad e incluso permitir compensaciones a través de la fusión de modelos, pero se sigue considerando que el ajuste de las instrucciones es el siguiente paso esencial, lo que refuerza el valor de ingresar señales de instrucciones durante el CPT.

Inyección de diversidad mediante la asignación al azar y la mezcla

Una estrategia general que ayuda a enseñar al modelo de manera eficaz a partir de los conjuntos de datos estructurados y semiestructurados consiste en mezclar el orden de los campos de los conjuntos de datos e, incluso, omitir algunas claves de forma aleatoria.

Al mezclar los campos, el modelo debe leer el significado de cada valor en lugar de dónde aparece y aprender las relaciones entre todos los campos. Por ejemplo, en el caso de un videojuego publicado en la tienda de Amazon, cuando “Título”, “Plataforma”, “Precio”, “Estado” y “Edición” aparecen en diferentes combinaciones, el modelo no puede confiar en que “el tercer espacio sea la plataforma”; debe vincular las etiquetas a los valores y aprender las relaciones bilaterales entre los atributos: título $\rightleftharpoons$ plataforma, plataforma $\rightleftharpoons$ precio, condición $\rightleftharpoons$ precio. Por lo tanto, puede, por ejemplo, deducir una plataforma probable a partir del nombre de un juego y un precio observado, o estimar un rango de precios plausible en función de un título y una plataforma.

Si se entregan las claves de forma aleatoria durante la serialización, se produce como si se eliminaran las características: se impide la adaptación simultánea en un campo concreto y se obliga al modelo a recuperar la información que falta a partir de las pruebas restantes. Si no aparece la palabra “Plataforma”, el modelo debe seleccionarla de la cadena de título o del texto de

compatibilidad; si “Precio” está oculto, debe separar la plataforma, la edición y el estado. Esto genera simetría ($A \rightarrow B$ y $B \rightarrow A$), robustez ante listados reales desordenados e invariabilidad del esquema cuando faltan campos, se les cambia el nombre o se reordenan.

Un ejemplo de estilo de compra lo concreta. Serialice el mismo objeto de varias formas (“Título: 'Elden Ring' | Plataforma: PlayStation 5 | Estado: Usado, como nuevo | Precio: 34,99 USD” y una permutación como “Precio: 34,99 USD | Título: 'Elden Ring' | Estado: Usado, como nuevo | Plataforma: PlayStation 5”) y, en algunas ocasiones, agregue “Plataforma” y deje “Compatible con PS5” en la descripción. Entrene objetivos complementarios, como predecir la plataforma a partir de {título, precio} y predecir un bucket de precio a partir de {título, plataforma}. Como el orden e incluso la presencia de las claves varían, la única estrategia estable es aprender las verdaderas relaciones entre los atributos en lugar de memorizar una plantilla.

Importancia de la forma en que se presentan los datos

Los LLM aprenden mediante la predicción del siguiente token a partir de lo que ya han visto. Por lo tanto, el orden de los campos y eventos que se muestran durante el entrenamiento decide lo que el modelo puede aprender. Si el formato de entrenamiento coincide con la tarea real, la pérdida recae en los tokens de decisión exactos. Si los campos se agrupan sin estructura, el modelo aprende los atajos o memoriza su popularidad y, después, falla cuando se le pide que elija entre las opciones.

Muestre primero la situación, después las opciones y, por último, la decisión. Si el modelo también debe conocer los resultados o las explicaciones, colóquelos después de la decisión.

Empaquetado de muestras para el CPT

¿Qué es el empaquetado?

Simplemente significa llenar cada ventana de secuencia de los datos de entrenamiento con varios ejemplos completos para que la ventana esté llena de tokens reales, no de relleno.

¿Por qué importa?

Durante el entrenamiento, se establece una longitud máxima de contexto; por ejemplo, 8192 tokens. Los lotes tienen la forma de [tamaño del lote × longitud del contexto]. Si un ejemplo de entrenamiento es más corto que la longitud del contexto, las posiciones restantes se rellenan. El relleno se sigue ejecutando en los kernels de atención y MLP, incluso si se oculta la pérdida, por lo que se paga el cálculo por los símbolos que no transmiten ninguna señal de aprendizaje.

¿Cómo se empaqueta?

Para empaquetar varias muestras, concatene varias muestras de entrenamiento con un separador [DOC] en medio (observe el espacio antes y después de [DOC]) de manera que la longitud total de las muestras esté por debajo de la longitud de contexto deseada.

Un documento empaquetado de ejemplo tendría el siguiente aspecto:

```
{"text": "training sample 1 [DOC] training sample 2 [DOC] training sample 3"}
```

Parámetros de ajuste del CPT

Entre los parámetros disponibles para el refinamiento con CPT, se incluyen los siguientes:

Configuración de una ejecución

- **name:** nombre descriptivo para el trabajo de entrenamiento. Ayuda a identificar el trabajo en la Consola de administración de AWS.
- **model_type:** variante del modelo de Amazon Nova que desea utilizar. Las opciones disponibles son `amazon.nova-2-lite-v1:0:256k`.
- **model_name_or_path:** ruta al modelo base que desea utilizar para el entrenamiento. Las opciones disponibles son `nova-lite-2/prod` o la ruta de S3 para el punto de comprobación de entrenamiento posterior (`s3://customer-escrow-bucket-unique_id/training_run_name`).
- **replicas:** número de instancias de computación que desea utilizar para entrenamiento distribuido. Los valores disponibles varían en función del modelo que elija. Amazon Nova Lite 2.0 admite 4, 8, 16 o 32 réplicas.
- **data_s3_path:** ubicación de S3 del conjunto de datos de entrenamiento, que es un archivo JSONL. Este archivo debe residir en la misma región y cuenta de AWS que el clúster. Todas las ubicaciones de S3 proporcionadas deben estar en la misma cuenta y región.
- **validation_data_s3_path** (opcional): ubicación de S3 del conjunto de datos de validación, que es un archivo JSONL. Este archivo debe residir en la misma cuenta y región que el clúster. Todas las ubicaciones de S3 proporcionadas deben estar en la misma cuenta y región.
- **output_s3_path:** ubicación de S3 donde se almacenan el manifiesto y los registros de TensorBoard. Todas las ubicaciones de S3 proporcionadas deben estar en la misma cuenta de AWS y región de AWS.
- **mlflow_tracking_uri:** ARN de la aplicación de MLFlow que se usará para los registros de MLFlow

- `mlflow_experiment_name`: nombre del experimento de MLFlow
- `mlflow_run_name`: nombre de la ejecución de MLFlow

Configuración de entrenamiento

- `max_length`: longitud máxima de la secuencia en tokens. Determina el tamaño de la ventana de contexto para entrenamiento. El valor máximo admitido es de 8192 tokens para CPT.

Las secuencias más largas mejorarán la eficiencia del entrenamiento a costa de aumentar los requisitos de memoria. Es recomendable que el parámetro `max_length` coincida con la distribución de datos.

- `global_batch_size`: número total de muestras de entrenamiento procesadas juntas en una sola pasada hacia delante o hacia atrás en todos los dispositivos y trabajadores.

Este valor multiplica el tamaño del lote por dispositivo y el número de dispositivos. Afecta a la estabilidad del entrenamiento y al rendimiento. Le recomendamos que comience con un tamaño de lote que se ajuste fácilmente a la memoria y, a partir de ahí, se escale verticalmente. En el caso de datos específicos de un dominio, es posible que los lotes de mayor tamaño suavicen en exceso los gradientes.

Configuración del entrenador

- `max_steps`: número de pasos de entrenamiento que se ejecutarán. Cada paso entrenará al modelo con el número de elementos de `global_batch_size`

Configuración del modelo

- `hidden_dropout`: probabilidad de eliminar salidas de estado ocultas. Aumente este valor aproximadamente 0,0-0,2 para reducir el ajuste excesivo en conjuntos de datos más pequeños. Los valores válidos van de 0 a 1, ambos inclusive.
- `attention_dropout`: probabilidad de perder ponderaciones de atención. Este parámetro puede ayudar en la generalización. Los valores válidos van de 0 a 1, ambos inclusive.

Configuración del optimizador

- `lr`: tasa de aprendizaje, que controla el tamaño de los pasos durante la optimización. Recomendamos valores entre $1e-6$ - $1e-4$ para un buen rendimiento. Los valores válidos van de 0 a 1, ambos inclusive.
- `name`: algoritmo del optimizador. En la actualidad, solo se admite `distributed_fused_adam`.
- `weight_decay`: fuerza de regularización de L2. Los valores más altos (entre 0,01 y 0,1) aumentan la regularización.
- `warmup_steps`: número de pasos para aumentar gradualmente la tasa de aprendizaje. Mejora la estabilidad del entrenamiento. Los valores válidos van de 1 a 20, ambos inclusive.
- `min_lr`: tasa mínima de aprendizaje al final de la degradación. Los valores válidos van de 0 a 1, ambos inclusive, pero deben ser inferiores a la tasa de aprendizaje.

Refinamiento supervisado (SFT)

El proceso de entrenamiento SFT consta de dos pasos principales:

- Preparación de datos: siga las pautas establecidas para crear, limpiar o reformatear conjuntos de datos para adaptarlos a la estructura requerida. Asegúrese de que las entradas, las salidas y la información auxiliar (como las pistas de razonamiento o los metadatos) estén adaptadas y formateadas correctamente.
- Configuración del entrenamiento: defina cómo se entrenará el modelo. Cuando se usa Amazon SageMaker HyperPod, esta configuración se escribe en un archivo de fórmulas YAML que incluye:
 - Rutas de orígenes de datos (conjuntos de datos de entrenamiento y validación)
 - Hiperparámetros clave (épocas, ritmo de aprendizaje, tamaño del lote)
 - Componentes opcionales (parámetros de entrenamiento distribuidos, etc.)

Comparación y selección de modelos de Nova

Amazon Nova 2.0 es un modelo entrenado en un conjunto de datos más amplio y diverso que Amazon Nova 1.0. Entre las características clave se incluyen las siguientes:

- Capacidades de razonamiento mejoradas que admiten el modo de razonamiento explícito
- Rendimiento multilingüe más amplio en varios otros idiomas
- Rendimiento mejorado en tareas complejas, como la codificación y el uso de herramientas
- Gestión ampliada del contexto con mayor precisión y estabilidad en contextos más largos

Cuándo usar Nova 1.0 en lugar de Nova 2.0

Elija Amazon Nova 2.0 en las siguientes situaciones:

- Se necesita un rendimiento superior con capacidades de razonamiento avanzadas.
- Se requiere soporte multilingüe o gestión de tareas complejas.
- Se necesitan mejores resultados en tareas de codificación, uso de herramientas o análisis.

SFT en Nova 2.0

Amazon Nova Lite 2.0 ofrece capacidades mejoradas para llevar a cabo el refinamiento supervisado, como el modo de razonamiento avanzado, una mejor comprensión multimodal y una gestión del contexto ampliado. El SFT en Nova 2.0 le permite adaptar estas potentes capacidades a sus casos de uso específicos y, al mismo tiempo, mantener el rendimiento superior del modelo en tareas complejas.

Las principales características del SFT en Nova 2.0 incluyen las siguientes:

- Compatibilidad con el modo de razonamiento: entrene los modelos para generar rastros de razonamiento explícitas antes de las respuestas finales a fin de mejorar las capacidades analíticas.
- Entrenamiento multimodal avanzado: refine la comprensión de documentos (PDF), la comprensión de videos y las tareas basadas en imágenes con mayor precisión.
- Capacidades de llamada a herramientas: entrene a los modelos para que utilicen de forma eficaz herramientas externas y funciones en flujos de trabajo complejos.
- Compatibilidad contextual ampliada: aproveche las ventanas contextuales más largas con mayor estabilidad y precisión para aplicaciones con un uso intensivo de documentos.

Note

Para obtener más información sobre qué contenedores, imágenes o ejemplos de fórmulas se deben utilizar, vaya a [Fórmulas de Amazon Nova](#).

Temas

- [Selección del modo de razonamiento \(solo en Nova 2.0\)](#)
- [Formato de los datos de llamadas a herramientas](#)

- [Formato de datos de la comprensión de documentos](#)
- [Comprensión de videos para el SFT](#)
- [Instrucciones para la carga de datos](#)
- [Creación de un trabajo de refinamiento](#)
- [Parámetros de ajuste del SFT](#)
- [Guía de hiperparámetros](#)

Fórmula del SFT de muestra

A continuación se muestra un ejemplo de fórmula para el SFT. Puedes encontrar esta fórmula y otras en el repositorio 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:               # Optimizer settings
  lr: 1e-5                  # Learning rate, must be between 0.0 and 1.0
  weight_decay: 0.0         # L2 regularization strength, must be between 0.0
and 1.0
  adam_beta1: 0.9           # Exponential decay rate for first-moment
estimates
  adam_beta2: 0.95          # Exponential decay rate for second-moment
estimates

peft:                       # Parameter-efficient fine-tuning (LoRA)
  peft_scheme: "null"       # Disable LoRA for PEFT

```

Selección del modo de razonamiento (solo en Nova 2.0)

Amazon Nova 2.0 admite el modo de razonamiento para capacidades analíticas mejoradas:

- Modo de razonamiento (activado):
 - Establezca `reasoning_enabled: true` en la configuración de entrenamiento.
 - El modelo se entrena para generar rastros de razonamiento antes de las respuestas finales.
 - Mejora el rendimiento en tareas de razonamiento complejas.
- Modo sin razonamiento (desactivado):
 - Establezca `reasoning_enabled: false` u omita el parámetro (opción predeterminada)
 - SFT estándar sin razonamiento explícito
 - Adecuado para tareas que no se benefician del razonamiento paso a paso

Note

- Cuando el razonamiento está activado, funciona con un esfuerzo de razonamiento alto. No existe ninguna opción de razonamiento bajo para el SFT.
- El contenido de razonamiento multimodal no es compatible con el SFT. El modo de razonamiento se aplica a las entradas de solo texto.

Uso del modo de razonamiento con conjuntos de datos sin razonamiento

Se permita entrenar a Amazon Nova con un conjunto de datos sin razonamiento con `reasoning_enabled: true`. Sin embargo, hacerlo puede provocar que el modelo pierda sus capacidades de razonamiento, ya que Amazon Nova aprende principalmente a generar las respuestas presentadas en los datos sin aplicar el razonamiento.

Si entrena a Amazon Nova en un conjunto de datos sin razonamiento, pero aun así desea usar el razonamiento durante la inferencia:

1. Desactive el razonamiento durante el entrenamiento (`reasoning_enabled: false`).
2. Active el razonamiento más adelante durante la inferencia.

Si bien este enfoque permite el razonamiento en el momento de la inferencia, no garantiza un rendimiento mejorado en comparación con la inferencia sin razonamiento.

Práctica recomendada: active el razonamiento tanto para el entrenamiento como para la inferencia cuando utilice conjuntos de datos de razonamiento y desactívelo para ambos cuando utilice conjuntos de datos sin razonamiento.

Note

Para obtener más información sobre qué contenedores, imágenes o ejemplos de fórmulas se deben utilizar, vaya a [Fórmulas de Amazon Nova](#).

Formato de los datos de llamadas a herramientas

El SFT admite modelos de entrenamiento para usar herramientas (llamadas a funciones). A continuación se muestra un ejemplo de formato de entrada para la llamada a herramientas:

Ejemplo 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?"
      ]
    ]
  }
]
}

```

Consideraciones importantes sobre los datos de llamadas a herramientas:

- ToolUse solo debe aparecer en los turnos del asistente.
- ToolResult solo debe aparecer en los turnos del usuario.
- ToolResult debe ser solo de texto o JSON, no se admiten actualmente otras modalidades para los modelos de Amazon Nova
- inputSchema en toolSpec debe ser un objeto de esquema JSON válido
- Cada ToolResult debe hacer referencia a un toolUseId válido de un ToolUse de asistente anterior, y cada toolUseId debe usarse exactamente una vez por conversación.

 Note

Para obtener más información sobre qué contenedores, imágenes o ejemplos de fórmulas se deben utilizar, vaya a [Fórmulas de Amazon Nova](#).

Formato de datos de la comprensión de documentos

El SFT admite modelos de entrenamiento en tareas de comprensión de documentos. A continuación se muestra un formato de entrada:

Ejemplo 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"  
      }  
    ]  
  }  
]  
}
```

Consideraciones importantes para la comprensión de documentos:

- Solo se admiten archivos PDF.
- El tamaño máximo del documento es de 10 MB.
- Una muestra puede contener documentos y texto, pero no puede mezclar documentos con otras modalidades (como imágenes o videos).

 Note

Para obtener más información sobre qué contenedores, imágenes o ejemplos de fórmulas se deben utilizar, vaya a [Fórmulas de Amazon Nova](#).

Comprensión de videos para el SFT

El SFT admite modelos de refinamiento para tareas de comprensión de videos. A continuación se muestra un formato de entrada:

Ejemplo 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"
        }
      ]
    }
  ]
}

```

Consideraciones importantes para la comprensión de videos:

- El tamaño máximo del video es de 50 MB.
- Los videos pueden durar hasta 15 minutos.

- Solo se permite un video por muestra; no se admiten varios videos en la misma muestra.
- Una muestra puede contener video y texto, pero no puede mezclar video con otras modalidades (como imágenes o documentos).

Note

Para obtener más información sobre qué contenedores, imágenes o ejemplos de fórmulas se deben utilizar, vaya a [Fórmulas de Amazon Nova](#).

Instrucciones para la carga de datos

Cargue conjuntos de datos de entrenamiento y validación en un bucket de S3. Especifique estas ubicaciones en el bloque `run` de la fórmula:

```
## Run config
run:
  ...
  data_s3_path: "s3://<bucket-name>/<training-directory>/<training-file>.jsonl"
```

Nota: Sustituya `<bucket-name>`, `<training-directory>`, `<validation-directory>`, `<training-file>` y `<validation-file>` por las rutas de S3 reales.

Nota: Los conjuntos de datos de validación no son compatibles actualmente con el SFT con Amazon Nova 2.0. Si se proporciona un conjunto de datos de validación, se ignorará.

Creación de un trabajo de refinamiento

Defina el modelo base mediante los campos `model_type` y `model_name_or_path` del bloque `run`:

```
## Run config
run:
  ...
  model_type: amazon.nova-2-lite-v1:0:256k
  model_name_or_path: nova-lite-2/prod
  ...
```

Parámetros de ajuste del SFT

Entre los parámetros de Amazon Nova disponibles para el ajuste con SFT, se incluyen los siguientes:

Configuración de una ejecución

- `name`: nombre descriptivo para el trabajo de entrenamiento. Ayuda a identificar el trabajo en la Consola de administración de AWS.
- `model_type`: variante del modelo de Amazon Nova que desea utilizar. Las opciones disponibles son `amazon.nova-2-lite-v1:0:256k`.
- `model_name_or_path`: ruta al modelo base que desea utilizar para el entrenamiento. Las opciones disponibles son `nova-lite-2/prod` o la ruta de S3 para el punto de comprobación de entrenamiento posterior (`s3://customer-escrow-bucket-unique_id/training_run_name`).
- `replicas`: número de instancias de computación que desea utilizar para entrenamiento distribuido. Los valores disponibles varían en función del modelo que elija. Amazon Nova Lite 2.0 admite 4, 8, 16 o 32 réplicas.
- `data_s3_path`: ubicación de S3 del conjunto de datos de entrenamiento, que es un archivo JSONL. Este archivo debe residir en la misma región y cuenta de AWS que el clúster. Todas las ubicaciones de S3 proporcionadas deben estar en la misma cuenta y región.
- `validation_data_s3_path` (opcional): ubicación de S3 del conjunto de datos de validación, que es un archivo JSONL. Este archivo debe residir en la misma cuenta y región que el clúster. Todas las ubicaciones de S3 proporcionadas deben estar en la misma cuenta y región.
- `output_s3_path`: ubicación de S3 donde se almacenan el manifiesto y los registros de TensorBoard. Todas las ubicaciones de S3 proporcionadas deben estar en la misma cuenta de AWS y región de AWS.
- `mlflow_tracking_uri`: ARN de la aplicación de MLFlow que se usará para los registros de MLFlow.
- `mlflow_experiment_name`: nombre del experimento de MLFlow.
- `mlflow_run_name`: nombre de la ejecución de MLFlow.

Configuración de entrenamiento

- `max_steps`: número de pasos de entrenamiento que se ejecutarán. Cada paso entrenará al modelo con el número de elementos de `global_batch_size`.

- `save_steps`: frecuencia (en pasos) con la que se guardan los puntos de control del modelo durante el entrenamiento.
- `save_top_k`: número máximo de los mejores puntos de control que se deben retener en función de las métricas de validación.
- `max_length`: longitud máxima de la secuencia en tokens. Determina el tamaño de la ventana de contexto para entrenamiento. El valor máximo admitido es de 32 768 tokens para el SFT.

Las secuencias más largas mejorarán la eficiencia del entrenamiento a costa de aumentar los requisitos de memoria. Es recomendable que el parámetro `max_length` coincida con la distribución de datos.

- `global_batch_size`: número total de muestras de entrenamiento procesadas juntas en una sola pasada hacia delante o hacia atrás en todos los dispositivos y trabajadores.

Este valor multiplica el tamaño del lote por dispositivo y el número de dispositivos. Afecta a la estabilidad del entrenamiento y al rendimiento. Le recomendamos que comience con un tamaño de lote que se ajuste fácilmente a la memoria y, a partir de ahí, se escale verticalmente. En el caso de datos específicos de un dominio, es posible que los lotes de mayor tamaño suavicen en exceso los gradientes.

- `reasoning_enabled`: indicador booleano para habilitar las capacidades de razonamiento durante el entrenamiento.

Programación de la tasa de aprendizaje

- `warmup_steps`: número de pasos para aumentar gradualmente la tasa de aprendizaje. Esto mejora la estabilidad del entrenamiento.
- `min_lr`: tasa mínima de aprendizaje al final de la degradación. Los valores válidos van de 0 a 1, ambos inclusive, pero deben ser inferiores a la tasa de aprendizaje.

Configuración del optimizador

- `lr`: tasa de aprendizaje, que controla el tamaño de los pasos durante la optimización. Recomendamos valores entre 1e-6-1e-4 para un buen rendimiento. Los valores válidos van de 0 a 1, ambos inclusive.
- `weight_decay`: fuerza de regularización de L2. Los valores más altos (entre 0,01 y 0,1) aumentan la regularización.

- `adam_beta1`: tasa de decremento exponencial para las estimaciones del primer momento en el optimizador Adam. El valor predeterminado es 0.9.
- `adam_beta2`: tasa de reducción exponencial para las estimaciones del segundo momento en el optimizador Adam. El valor predeterminado es 0.95.

Configuración del PEFT

- `peft_scheme`: el esquema de refinamiento preciso que se debe utilizar con eficiencia de parámetros. Las opciones son `'null'` para un refinamiento de rango completo o `lora` para un refinamiento basado en LoRA.

Ajuste de LoRA (cuando `peft_scheme` es "lora")

- `alpha`: parámetro de escalado de LoRA. Controla la magnitud de la adaptación de rango bajo. Los valores típicos están comprendidos entre 8 y 128.
- `lora_plus_lr_ratio`: porcentaje de tasa de aprendizaje para la optimización de LoRA+. Este multiplicador ajusta la tasa de aprendizaje específicamente para los parámetros de LoRA.

Guía de hiperparámetros

Utilice los siguientes hiperparámetros recomendados en función del enfoque de entrenamiento:

Entrenamiento de rango completo

- Épocas: 1
- Tasa de aprendizaje (`lr`): 1e-5
- Tasa mínima de aprendizaje (`min_lr`): 1e-6

LoRA (adaptación de rango bajo)

- Épocas: 2
- Tasa de aprendizaje (`lr`): 5e-5
- Tasa mínima de aprendizaje (`min_lr`): 1e-6

Nota: Ajuste estos valores en función del tamaño del conjunto de datos y del rendimiento de la validación. Supervise las métricas de entrenamiento para evitar el sobreajuste.

Refinamiento por refuerzo (RFT) en SageMaker HyperPod

El refinamiento por refuerzo (RFT) es una técnica de machine learning que mejora el rendimiento del modelo mediante señales de comentarios (puntuaciones medibles o recompensas que indican la calidad de la respuesta) en lugar de una supervisión directa con respuestas exactas y correctas. A diferencia del refinamiento supervisado tradicional, que aprende de los pares de entradas y salidas, el RFT utiliza funciones de recompensas para evaluar las respuestas del modelo y lo optimiza de forma iterativa para maximizar estas recompensas.

Este enfoque es particularmente eficaz para tareas en las que es difícil definir el resultado exacto correcto, pero le permite medir de forma fiable la calidad de la respuesta. El RFT permite a los modelos aprender comportamientos y preferencias complejos mediante pruebas y comentarios, lo que lo hace ideal para aplicaciones que requieren una toma de decisiones matizada, una resolución de problemas creativa o el cumplimiento de criterios de calidad específicos que se pueden evaluar mediante programación.

Cuándo se debe usar el RFT

Utilice el RFT cuando pueda definir criterios de éxito claros y medibles, pero tenga dificultades para proporcionar resultados exactos y correctos para el entrenamiento. Es ideal para tareas en las que la calidad es subjetiva o multifacética, como la redacción creativa, la optimización del código o el razonamiento complejo, en las que existen varias soluciones válidas, pero algunas son claramente mejores que otras.

El RFT funciona mejor cuando se cuenta con lo siguiente:

- Una función de recompensa fiable que pueda evaluar los resultados del modelo mediante programación
- Necesidad de alinear el comportamiento del modelo con preferencias o restricciones específicas
- Situaciones en las que el refinamiento supervisado tradicional no es suficiente porque recopilar ejemplos etiquetados de alta calidad es caro o poco práctico

Considere el uso del RFT para aplicaciones que requieran mejoras iterativas, personalización o el cumplimiento de reglas empresariales complejas que puedan codificarse como señales de recompensa.

¿Para qué es más adecuado el RFT?

El RFT sobresale en dominios en los que la calidad de los resultados se puede medir objetivamente, pero las respuestas óptimas son difíciles de definir por adelantado:

- Resolución de problemas matemáticos: precisión verificable con varias rutas de solución
- Generación y optimización de código: resultados de ejecución y métricas de rendimiento comprobables
- Tareas de razonamiento científico: coherencia lógica y precisión fáctica
- Análisis de datos estructurados: salidas verificables mediante programación
- Razonamiento en varios pasos: tareas que requieren una progresión lógica gradual
- Uso de herramientas y llamadas a la API: éxito medible por resultados de ejecución
- Flujos de trabajo complejos: cumplimiento de restricciones y normas empresariales específicas

El RFT funciona excepcionalmente bien cuando se necesita equilibrar varios objetivos contrapuestos, como la precisión, la eficiencia y el estilo.

Cuándo se debe usar el modo de razonamiento para el entrenamiento con el RFT

Amazon Nova 2.0 admite el modo razonamiento durante el entrenamiento con el RFT. Están disponibles los siguientes modos:

- ninguno: sin razonamiento (omite el campo `reasoning_effort`)
- bajo: sobrecarga de razonamiento mínima
- alto: capacidad de razonamiento máxima (opción predeterminada cuando se especifica `reasoning_effort`)

Note

No hay una opción media para el RFT. Si el campo `reasoning_effort` no está en la configuración, el razonamiento está desactivado.

Utilice un razonamiento alto para lo siguiente:

- Tareas analíticas complejas

- Resolución de problemas matemáticos
- Deducción lógica de varios pasos
- Tareas en las que pensar paso a paso agrega valor

Utilice ninguno (omite reasoning_effort) o un razonamiento bajo para lo siguiente:

- Consultas de hechos sencillas
- Clasificaciones directas
- Optimización de velocidad y costo
- Preguntas y respuestas directas

Important

Los modos de razonamiento superior aumentan el tiempo y el costo del entrenamiento, la latencia y el costo de la inferencia, pero también aumentan la capacidad del modelo para tareas de razonamiento complejas.

Modelos compatibles

El RFT en SageMaker HyperPod es compatible con Amazon Nova Lite 2.0 (amazon.nova-2-lite-v1:0:256k).

Pasos principales

El proceso de RFT consta de cuatro fases clave:

- Implementación de un evaluador: cree una función de recompensa para puntuar mediante programación las respuestas del modelo en función de sus criterios de calidad.
- Carga de peticiones: prepare y cargue los datos de entrenamiento en el formato conversacional especificado con datos de referencia para su evaluación.
- Inicio de un trabajo: inicie el proceso de refinamiento por refuerzo con los parámetros configurados.
- Supervisión: haga un seguimiento del progreso del entrenamiento a través de paneles de métricas para garantizar que el modelo aprenda de forma eficaz.

Cada paso se basa en el anterior, y el evaluador es la base que guía todo el proceso de entrenamiento al proporcionar señales de comentarios coherentes.

Temas

- [RFT en Nova 2.0](#)

RFT en Nova 2.0

Los datos de entrenamiento del RFT siguen el formato conversacional de OpenAI. Cada ejemplo de entrenamiento es un objeto JSON que contiene mensajes, respuestas de referencia y definiciones de herramientas opcionales. En esta sección, se proporciona orientación sobre cómo preparar datos de entrenamiento efectivos para el RFT en Nova 2.0.

Temas

- [Formato y estructura de los datos](#)
- [Descripción del campo](#)
- [Guía de hiperparámetros](#)
- [Propiedades adicionales](#)
- [Recomendaciones de tamaño de conjunto de datos](#)
- [Características de los datos de entrenamiento eficaces](#)
- [Supervisión del entrenamiento RFT](#)

Formato y estructura de los datos

Cada ejemplo de entrenamiento es un objeto JSON que contiene lo siguiente:

- `messages`: matriz de turnos de conversación en los que se utilizan los roles de sistema, usuario y, opcionalmente, asistente
- `reference_answer`: salida esperada o criterio de evaluación para el cálculo de la recompensa
- `tools` (opcional): matriz de definiciones de funciones disponibles para el modelo
- `id` (opcional): identificador único para el seguimiento y la deduplicación

Cada ejemplo debe estar en una sola línea del archivo JSONL, con un objeto JSON por línea.

Ejemplo 1: problema de química

En el siguiente ejemplo, se muestra un problema de química con una respuesta de referencia que contiene valores de datos reales:

```
{
  "id": "chem-001",
  "messages": [
    {
      "role": "system",
      "content": "You are a helpful chemistry assistant"
    },
    {
      "role": "user",
      "content": "Predict hydrogen bond donors and acceptors for this SMILES:
CCN(CC)CCC(=O)c1sc(N)nc1C"
    }
  ],
  "reference_answer": {
    "donor_bond_counts": 2,
    "acceptor_bond_counts": 4,
    "explanation": "Calculated using Lipinski's rule of five: N-H groups (2 donors), N
and 0 atoms with lone pairs (4 acceptors)"
  }
}
```

Note

El valor de `reference_answer` contiene valores de datos reales calculados mediante reglas específicas del dominio. La función de recompensa compara los valores de predicción del modelo con estos valores de referencia para calcular una puntuación de recompensa.

Ejemplo 2: problema matemático

En el siguiente ejemplo, se muestra un problema matemático con los pasos de resolución:

```
{
  "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": [" $2x = 13 - 5$ ", " $2x = 8$ ", " $x = 4$ "]
}
}

```

Ejemplo 3: uso de herramientas

En el siguiente ejemplo, se muestra el uso de herramientas con el comportamiento 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"
}
}

```

Descripción del campo

Campo	Descripción	Notas adicionales	Obligatorio
id	Identificador único para este ejemplo de RFT	Cadena (por ejemplo, “sample-001”). Útil para el seguimiento y la deduplicación.	No
Mensajes	Lista ordenada de mensajes de chat que definen la petición y el contexto	Una matriz de objetos . El modelo los ve en orden. Normalmente comienza con un mensaje del sistema y luego con el usuario.	Sí
messages[].role	Quién habla en el mensaje	Valores comunes: “sistema”, “usuario” (a veces “asistente” en otros contextos).	No

Campo	Descripción	Notas adicionales	Obligatorio
messages[].content	Contenido del texto del mensaje	Cadena sin formato. Para el sistema son instrucciones, para el usuario son la tarea o entrada.	No
herramientas	Especificaciones de la herramienta disponibles para el modelo en este ejemplo	Matriz. Cada elemento define la interfaz y los metadatos de una herramienta. Los tipos pueden incluir “función” o “interno”.	No
reference_answer	Salida esperada del modelo para este ejemplo	Cadena u objeto según la tarea. Se utiliza como destino para la evaluación o el entrenamiento.	No

Note

Los campos personalizados adicionales (por ejemplo, task_id, difficulty_level, context_data) no se validan y se pasarán a la función de recompensas como metadatos.

Guía de hiperparámetros

Utilice los siguientes hiperparámetros recomendados en función de su enfoque de entrenamiento:

General:

- Épocas: 1
- Tasa de aprendizaje (lr): 1e-7
- Número de generaciones: 8

- Máximo de tokens nuevos: 8192
- Tamaño del lote: 256

LoRA (adaptación de rango bajo):

- Rango de LoRA: 32

Note

Ajuste estos valores en función del tamaño del conjunto de datos y del rendimiento de la validación. Supervise las métricas de entrenamiento para evitar el sobreajuste.

Propiedades adicionales

La configuración “additionalProperties”: true le permite incluir campos personalizados más allá de los requisitos básicos del esquema, lo que proporciona flexibilidad para agregar cualquier dato que la función de recompensas necesite para una evaluación adecuada.

Campos adicionales comunes

Puede incluir los siguientes tipos de campos adicionales:

Metadatos:

- task_id: identificador único para el seguimiento
- difficulty_level: indicador de complejidad del problema
- domain: categoría o área del asunto
- expected_reasoning_steps: número de pasos de la solución

Criterios de evaluación:

- valuation_criteria: rúbricas de calificación específicas
- custom_scoring_weights: importancia relativa de los diferentes aspectos
- context_data: información básica del problema
- external_references: enlaces a documentación o recursos relevantes

Ejemplo con propiedades adicionales

En el siguiente ejemplo, se incluyen campos de metadatos 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
}
```

Recomendaciones de tamaño de conjunto de datos

Punto de partida

Comience con los siguientes tamaños mínimos de conjuntos de datos:

- Mínimo 100 ejemplos de entrenamiento
- Mínimo 100 ejemplos de evaluación

Priorice los datos de entrada de alta calidad y una función de recompensa fiable que se ejecute de manera coherente en las respuestas del modelo.

Enfoque de priorización de la evaluación

Antes de invertir en un entrenamiento RFT a gran escala, evalúe el rendimiento de línea de base del modelo:

- Alto rendimiento (recompensa superior al 95 %): el RFT puede no ser necesario, el modelo ya funciona bien.
- Rendimiento muy bajo (recompensa del 0 %): cambie primero al SFT para establecer las capacidades básicas.
- Rendimiento moderado: es probable que el RFT sea adecuado.

Este enfoque de priorización de la evaluación garantiza que la función de recompensa no tenga errores y determina si el RFT es el método adecuado para su caso de uso. Empezar poco a poco le permite familiarizarse con el flujo de trabajo del RFT, identificar y solucionar los problemas con antelación, validar su enfoque antes de escalar verticalmente y probar la fiabilidad de la función de recompensas. Una vez validado, puede ampliarlo a conjuntos de datos más grandes para mejorar aún más el rendimiento.

Características de los datos de entrenamiento eficaces

Claridad y coherencia

Los buenos ejemplos del RFT requieren datos de entrada claros e inequívocos que permitan un cálculo preciso de las recompensas en las diferentes salidas del modelo. Evite el ruido en los datos, lo que incluye lo siguiente:

- Formato incoherente
- Etiquetas o instrucciones contradictorias
- Peticiones ambiguas
- Conflictos en las respuestas de referencia

Cualquier ambigüedad inducirá a error durante el proceso de entrenamiento y provocará que el modelo aprenda comportamientos no deseados.

Diversidad

El conjunto de datos debe capturar toda la diversidad de casos de uso de producción para garantizar un rendimiento real sólido. Incluya:

- Varios tipos de problemas y niveles de dificultad
- Diferentes formatos de entrada y casos extremos
- Muestras representativas de todos los escenarios esperados

Esta diversidad ayuda a evitar el sobreajuste y garantiza que el modelo gestione sin problemas las entradas desconocidas.

Consideraciones sobre la función de recompensas

Diseñe la función de recompensas para un entrenamiento eficiente:

- Ejecución en segundos (no minutos)
- Paralelización eficaz con Lambda
- Devolución de puntuaciones coherentes y fiables
- Gestión de diferentes tipos de salidas del modelo sin problemas

Las funciones de recompensas rápidas y escalables permiten una iteración rápida y una experimentación rentable a escala.

Supervisión del entrenamiento RFT

Supervise las métricas clave durante el entrenamiento para garantizar un aprendizaje efectivo e identificar los posibles problemas a tiempo.

Temas

- [Métricas clave para hacer un seguimiento](#)
- [Evaluación después del RFT](#)
- [Uso de modelos de ajuste fino](#)
- [Limitaciones y prácticas recomendadas](#)
- [Solución de problemas](#)

Métricas clave para hacer un seguimiento

Supervise las siguientes métricas con MLFlow durante el entrenamiento:

Métricas de recompensas

- Puntuación media de recompensas: calidad general de las respuestas del modelo (debería aumentar con el tiempo)
- Distribución de recompensas: porcentaje de respuestas que reciben recompensas altas, medias y bajas

- Recompensas de entrenamiento y validación: comparación para detectar el sobreajuste

Métricas de entrenamiento:

- Actualizaciones de políticas: número de actualizaciones de peso correctas
- Tasa de finalización de despliegues: porcentaje de muestras evaluadas correctamente

Patrones preocupantes:

- Estancamiento de las recompensas (indica un aprendizaje deficiente)
- Disminución de recompensas de validación con aumento de recompensas de entrenamiento (sobreajuste)
- Aumento significativo de la variación de recompensas con el tiempo (inestabilidad)
- Alto porcentaje de errores en funciones de recompensas (problemas de implementación)

Cuándo se debe detener el entrenamiento:

- Se alcanzan las métricas de rendimiento objetivo.
- Las recompensas se estancan y ya no mejoran.
- El rendimiento de la validación se degrada (se detecta un sobreajuste).
- Se alcanza el presupuesto máximo del entrenamiento.

Evaluación después del RFT

Una vez completado el entrenamiento, evalúe el modelo de ajuste fino para evaluar las mejoras en el rendimiento:

- Ejecute un trabajo de evaluación del RFT: utilice el punto de control del entrenamiento RFT como modelo.
- Compárelo con la línea de base: evalúe tanto el modelo base como el modelo de ajuste fino en el mismo conjunto de pruebas.
- Analice las métricas: revise las métricas específicas de la tarea (precisión, puntuación de las recompensas, etc.).
- Lleve a cabo una revisión cualitativa: inspeccione manualmente las salidas de las muestras para comprobar su calidad.

Para conocer los procedimientos de evaluación detallados, consulte la sección Evaluación.

Uso de modelos de ajuste fino

Acceso a los puntos de control:

Una vez completado el entrenamiento, localice el punto de control:

1. Vaya a su `output_path` en S3.
2. Descargue y extraiga `output.tar.gz`.
3. Abra `.manifest.json`
4. Copie el valor `checkpoint_s3_bucket`.

Despliegue para la inferencia:

Utilice la ruta del punto de control de S3 para la inferencia o un entrenamiento 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 obtener instrucciones de implementación e inferencia, consulte la sección Inferencia.

Limitaciones y prácticas recomendadas

Limitaciones actuales:

Restricciones de la versión beta:

- Necesito crear un nuevo grupo RIG para el RFT. Se resolverá esta limitación en la GA.
- Requisitos de tipo de instancia: solo se admiten instancias P5 (mínimo 8x P5.48xlarge).
Próximamente: compatibilidad con tipos de instancias más pequeños (fecha estimada: mediados de enero de 2025).

Limitaciones funcionales:

- Tiempo de espera de Lambda de 15 minutos: las funciones de recompensas deben completarse en 15 minutos.
- Solo turno único: no se admiten conversaciones de varios turnos.

- Conjuntos de datos de validación: no se admiten durante el entrenamiento. Utilice trabajos de evaluación independientes para evaluar el progreso del entrenamiento.

Consideraciones sobre el entrenamiento:

- Escenarios de recompensas bajas: puede tener problemas cuando menos del 5 % de los ejemplos reciben recompensas positivas; opte primero por el SFT.
- Requisitos de datos: necesita suficiente diversidad para aprender de forma eficaz.
- Costo computacional: es más caro que el refinamiento supervisado.

Nova Forge elimina algunas de estas limitaciones:

- Admite conversaciones de varios turnos.
- Permite funciones de recompensas que superen los tiempos de espera de 15 minutos.
- Proporciona algoritmos avanzados y opciones de ajuste.
- Se ha diseñado para casos de uso empresarial complejos, ajustados específicamente para crear modelos de frontera.

Prácticas recomendadas:

Inicio con algo pequeño y escalado:

- Comience con conjuntos de datos mínimos (de 100 a 200 ejemplos) y pocas épocas de entrenamiento.
- Valide el enfoque antes de escalar verticalmente.
- Aumente gradualmente el tamaño del conjunto de datos y los pasos de entrenamiento en función de los resultados.

Línea de base con prioridad del SFT:

- Si las puntuaciones de recompensas son coherentemente bajas (por ejemplo, siempre 0), lleve a cabo el SFT antes que el RFT.
- El RFT requiere un rendimiento de línea de base razonable para mejorar de forma eficaz.

Diseño de funciones de recompensas eficientes:

- Ejecute en segundos, no minutos.
- Minimice las llamadas a la API externa.
- Utilice algoritmos y estructuras de datos eficientes.
- Implemente una gestión de errores adecuada.
- Lleve a cabo pruebas exhaustivas antes del entrenamiento.
- Aproveche las capacidades de escalado paralelo de Lambda.

Supervisión activa del entrenamiento:

- Haga un seguimiento del promedio de las puntuaciones de recompensas con el tiempo.
- Observe la distribución de las recompensas entre las muestras.
- Compare las recompensas de entrenamiento con las de validación.
- Busque patrones preocupantes (estancamiento, sobreajuste, inestabilidad).

Iteración en función de los resultados:

- Si las recompensas no mejoran después de varias iteraciones, ajuste el diseño de la función de recompensas.
- Aumente la diversidad de los conjuntos de datos para proporcionar señales de aprendizaje más claras.
- Considere la posibilidad de cambiar al SFT si las recompensas siguen siendo casi nulas.
- Experimente con diferentes hiperparámetros (tasa de aprendizaje, tamaño del lote).

Optimización de la calidad de los datos:

- Garantice ejemplos diversos y representativos.
- Incluya casos extremos y muestras difíciles.
- Verifique que la función de recompensas puntúe correctamente todos los tipos de ejemplos.
- Elimine o corrija las muestras que confundan a la función de recompensas.

Solución de problemas

Errores en la función de recompensas:

Síntomas: tasa de errores elevada en las llamadas a la función de recompensas durante el entrenamiento

Problema	Síntomas	Resolución
Tiempo de espera de Lambda	Tiempos de espera frecuentes después de 15 minutos	Optimice el rendimiento de las funciones; considere el uso de Nova Forge para evaluaciones complejas
Simultaneidad insuficiente	Errores de limitación de Lambda	Aumente <code>lambda_concurrency_limit</code> o solicite un aumento de cuota.
Formato de devolución no válido	Errores de formato en el entrenamiento	Compruebe que la estructura de devoluciones coincida con el formato de interfaz requerido.
Excepciones no gestionadas	Errores intermitentes	Agregue gestión y registro integrales de errores.
Errores de API externos	Puntuación incoherente	Implemente una lógica de reintentos y estrategias alternativas.

Rendimiento de entrenamiento deficiente:

Síntomas: las recompensas no mejoran o se estancan en valores bajos.

Resoluciones:

- Verifique la corrección de la función de recompensas: pruebe con ejemplos buenos o malos conocidos.
- Compruebe el rendimiento de la línea de base: evalúe el modelo base; si la precisión es cercana a cero, lleve a cabo antes el SFT.
- Aumente la diversidad de los datos: agregue ejemplos más variados que cubran diferentes escenarios

- Ajuste los hiperparámetros: pruebe diferentes tasas de aprendizaje o tamaños de lotes.
- Revise la calidad de la señal de las recompensas: asegúrese de que las recompensas diferencien entre respuestas buenas y malas.

Sobreajuste:

Síntomas: las recompensas de entrenamiento aumentan mientras que las de validación disminuyen.

Resoluciones:

- Reduzca los pasos de entrenamiento: deje de entrenar antes.
- Aumente el tamaño del conjunto de datos: agregue más ejemplos de entrenamiento.
- Agregue regularización: ajuste `weight_decay` o `entropy_coeff`.
- Aumente la diversidad de los datos: asegúrese de que el conjunto de entrenamiento represente una distribución completa.

Evaluación del modelo entrenado

Una fórmula de evaluación es un archivo de configuración YAML que define cómo se ejecuta el trabajo de evaluación de modelos de Amazon Nova. Con esta fórmula, puede evaluar el rendimiento de un modelo básico o entrenado mediante su comparación con puntos de referencia comunes o con sus propios conjuntos de datos personalizados. Las métricas se pueden almacenar en Amazon S3 o en TensorBoard. La evaluación proporciona métricas cuantitativas que le ayudan a evaluar el rendimiento del modelo en diversas tareas para determinar si es necesaria una mayor personalización.

La evaluación de los modelos es un proceso fuera de línea, en el que estos se prueban comparándolos con puntos de referencia fijos con respuestas predefinidas. No se evalúan en tiempo real ni en función de las interacciones de los usuarios en directo. Para evaluaciones en tiempo real, puede evaluar el modelo después de implementarlo en Amazon Bedrock llamando a las API de tiempo de ejecución de Amazon Bedrock.

Important

El contenedor de evaluación solo es compatible con los puntos de control generados por la propia plataforma de entrenamiento. Los puntos de control creados con SageMaker HyperPod solo pueden evaluarse mediante el flujo de trabajo de evaluación de SageMaker

HyperPod; en cambio, los puntos de control creados con los trabajos de entrenamiento de SageMaker solo pueden evaluarse mediante el flujo de trabajo de evaluación de los trabajos de entrenamiento de SageMaker. Se producirá un error si se intenta evaluar un punto de control desde una plataforma distinta.

Temas

- [Tareas de referencia disponibles](#)
- [Comprensión de los parámetros de fórmula](#)
- [Ejemplos de fórmula de evaluación](#)
- [Inicio de un trabajo de evaluación](#)
- [Acceso y análisis de los resultados de la evaluación](#)
- [Evaluación del RFT](#)

Tareas de referencia disponibles

Hay un paquete de códigos de ejemplo que muestra cómo calcular métricas de referencia mediante la característica de evaluación de modelos de SageMaker AI para Amazon Nova. Para acceder a los paquetes de códigos, consulte [sample-Nova-lighteval-custom-task](#).

A continuación se muestra una lista de las referencias estándar del sector disponibles y compatibles. Puede especificar las siguientes referencias para el parámetro `eval_task`:

Referencia	Modalidad	Descripción	Métricas	Strategy (Estrategia)	Subtarea disponible
mmlu	Texto	Comprensión del lenguaje multitarea: evalúa los conocimientos sobre 57 materias.	precisión	zs_cot	Sí
mmlu_pro	Texto	MMLU (subconjunto)	precisión	zs_cot	No

Referencia	Modalidad	Descripción	Métricas	Strategy (Estrategia)	Subtarea disponible
		nto profesion al): se centra en dominios profesion ales como derecho, medicina, contabilidad e ingeniería.			
bbh	Texto	Tareas de razonamiento avanzado: conjunto de problemas complejos que ponen a prueba las habilidades cognitivas y de resolución de problemas de nivel superior.	precisión	zs_cot	Sí

Referencia	Modalidad	Descripción	Métricas	Strategy (Estrategia)	Subtarea disponible
gpqa	Texto	Respuesta a preguntas de física general: evalúa la comprensión de conceptos de física y habilidades relaciona das con la resolución de problemas.	precisión	zs_cot	No
math	Texto	Resolución de problemas matemáticos: mide el razonamiento matemático en temas como álgebra, cálculo y problemas verbales.	exact_match	zs_cot	Sí

Referencia	Modalidad	Descripción	Métricas	Strategy (Estrategia)	Subtarea disponible
strong_reject	Texto	Tarea de control de calidad: prueba la capacidad del modelo para detectar y rechazar contenido inapropiado, dañino o incorrecto.	desviación	zs	Sí
IFEval	Texto	Evaluación de seguimiento de instrucciones: mide la precisión con la que un modelo sigue las instrucciones dadas y completa las tareas según las especificaciones.	precisión	zs	No

Referencia	Modalidad	Descripción	Métricas	Strategy (Estrategia)	Subtarea disponible
gen_qa	Texto	Evaluación personalizada de conjuntos de datos: permite utilizar un conjunto de datos propio para realizar evaluaciones comparativas y comparar resultados del modelo con respuestas de referencia con métricas como ROUGE y BLEU.	all	gen_qa	No

Referencia	Modalidad	Descripción	Métricas	Strategy (Estrategia)	Subtarea disponible
llm_judge	Texto	Comparación de preferencias de LLM como juez: utiliza un modelo de juez de Amazon Nova para determinar la preferencia entre las respuestas emparejadas (B en comparación con A) para las peticiones, con un cálculo de la probabilidad de que se prefiera B a A.	all	judge	No

Referencia	Modalidad	Descripción	Métricas	Strategy (Estrategia)	Subtarea disponible
humaneval	Texto	HumanEval : conjunto de datos de referencia diseñado para evaluar las capacidad es de generación de código de modelos de lenguaje de gran tamaño	pass@1	zs	No
mm_llm_judge	Multimodal (imagen)	Esta nueva prueba comparativa se comporta igual que la indicada anteriorment e, llm_judge , la cual está basada en texto. La única diferencia es que admite la inferencia de imágenes.	all	judge	No

Referencia	Modalidad	Descripción	Métricas	Strategy (Estrategia)	Subtarea disponible
rubric_llm_judge	Text	Rubric Judge es un modelo de evaluación mejorado de LLM como juez basado en Amazon Nova 2.0 Lite. A diferencia del modelo juez original , que solo proporciona veredictos preferenciales, Rubric Judge genera de forma dinámica criterios de evaluación personalizados adaptados a cada petición y puntúa de forma detallada varias dimensiones.	all	judge	No

Referencia	Modalidad	Descripción	Métricas	Strategy (Estrategia)	Subtarea disponible
aime_2024	Text	AIME 2024: problemas del American Invitational Mathematics Examination (AIME) que ponen a prueba el razonamiento matemático avanzado y la resolución de problemas	exact_match	zs_cot	No
calendar_scheduling	Text	Natural Plan: tarea de planificación de calendario que ponen a prueba las capacidades de planificación para programar reuniones a lo largo de varios días y con múltiples personas	exact_match	fs	No

Están disponibles las siguientes subtareas de mm1u:

```
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"  
]
```

Están disponibles las siguientes subtareas de 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"  
]
```

Están disponibles las siguientes subtarefas de math:

```
MATH_SUBTASKS = [  
    "algebra",  
    "counting_and_probability",  
    "geometry",  
    "intermediate_algebra",  
    "number_theory",  
    "prealgebra",  
    "precalculus",  
]
```

Comprensión de los parámetros de fórmula

Configuración de una ejecución

A continuación se ofrece una configuración de ejecución general y una explicación de los parámetros que intervienen.

```
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:** (obligatorio) nombre descriptivo del trabajo de evaluación. Ayuda a identificar el trabajo en la consola de AWS.
- **model_type:** (obligatorio) especifica la variante del modelo de Amazon Nova que se va a utilizar. No modifique manualmente este campo. Las opciones son:
 - `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`: (obligatorio) ruta al modelo base o ruta de S3 para el punto de comprobación entrenado posteriormente. Las opciones son:
 - `nova-micro/prod`
 - `nova-lite/prod`
 - `nova-pro/prod`
 - `nova-lite-2/prod`
 - (Ruta de S3 para el punto de comprobación entrenado posteriormente) `s3://<escrow bucket>/<job id>/outputs/checkpoints`
- `replicas`: (obligatorio) número de instancias de computación que desea utilizar para entrenamiento distribuido. Debe establecer este valor en 1 porque no se admite el uso de varios nodos.
- `data_s3_path`: (obligatorio) ruta de S3 al conjunto de datos de entrada. Deje este parámetro en blanco a menos que esté utilizando la fórmula uso del conjunto de datos propio o LLM como juez.
- `output_s3_path`: (obligatorio) ruta de S3 para almacenar artefactos de evaluación de salida. Tenga en cuenta que el bucket de S3 de salida debe crearlo la misma cuenta que está creando el trabajo.
- `mlflow_tracking_uri`: (opcional) ARN del servidor de seguimiento de MLflow para rastrear las puestas en marcha o experimentos de MLflow. Asegúrese de tener permiso para acceder al servidor de seguimiento desde el rol de puesta en marcha de SageMaker AI

Configuración de evaluación

A continuación se ofrece una configuración de evaluación de modelos y una explicación de los parámetros que intervienen.

```
evaluation:
  task: mmlu
  strategy: zs_cot
  subtask: mathematics
  metric: accuracy
```

- `task`: (obligatorio) Especifica la referencia o la tarea de evaluación que se va a utilizar.

Lista de tareas admitidas:

- 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: (obligatorio) define el enfoque de evaluación:
 - zs_cot: cadena de pensamientos de cero intentos: enfoque para realizar peticiones a modelos de lenguaje de gran tamaño que fomenta el razonamiento paso a paso sin necesidad de ejemplos explícitos.
 - zs: cero intentos: enfoque para resolver un problema sin ejemplos de entrenamiento anteriores.
 - gen_qa: estrategia específica para crear fórmulas de conjuntos de datos propias.
 - judge: estrategia específica para el LLM como juez de Amazon Nova y mm_llm_judge.
- subtask: (opcional y eliminable) especifica una subtarea específica para determinadas tareas de evaluación. Elimine esta opción de la fórmula si la tarea no tiene ninguna subtarea.
- metric: (obligatorio) métrica de evaluación que se va a utilizar.
 - accuracy: porcentaje de respuestas correctas
 - exact_match: (para referencia math), devuelve la velocidad a la que las cadenas de entrada previstas coinciden exactamente con sus referencias.
 - deflection: (para referencia strong_reject), devuelve la deflexión relativa al modelo base y la diferencia en las métricas de importancia.

- `pass@1`: (para referencia `humaneval`) es una métrica que se utiliza para medir el porcentaje de casos en los que la predicción de mayor confianza del modelo coincide con la respuesta correcta.
- `all`: devuelve las siguientes métricas:
 - Para `gen_qa` y uso de su propia referencia de conjunto de datos, devuelve las siguientes métricas:
 - `rouge1`: mide la superposición de unigramas (palabras individuales) entre texto generado y de referencia.
 - `rouge2`: mide la superposición de bigramas (dos palabras consecutivas) entre texto generado y de referencia.
 - `rougeL`: mide la subsecuencia común más larga entre textos, por lo que puede haber lagunas en la coincidencia.
 - `exact_match`: puntuación binaria (0 o 1) que indica si el texto generado coincide exactamente con el texto de referencia, carácter por carácter.
 - `quasi_exact_match`: similar a la coincidencia exacta, pero más flexible, pues suele ignorar el uso de mayúsculas y minúsculas, los signos de puntuación y los espacios en blanco.
 - `f1_score`: media armónica de precisión y recuperación que mide la superposición de palabras entre respuestas previstas y de referencia.
 - `f1_score_quasi`: similar a `f1_score`, pero con una coincidencia más flexible, utiliza una comparación de texto normalizada que no tiene en cuenta pequeñas diferencias.
 - `bleu`: mide la precisión de las coincidencias de n-gramas entre texto generado y de referencia, suele utilizarse en la evaluación de traducciones.
 - En el caso de `llm_judge` y `mm_llm_judge` con su propio conjunto de datos comparativo, devuelve las siguientes métricas:
 - `a_scores`: número de aciertos para `response_A` en pasadas de evaluación hacia delante y hacia atrás.
 - `a_scores_stderr`: error estándar de `response_A scores` en juicios por pares.
 - `b_scores`: número de aciertos para `response_B` en pasadas de evaluación hacia delante y hacia atrás.
 - `b_scores_stderr`: error estándar de `response_B scores` en juicios por pares.
 - `ties`: número de juicios en los que se evalúa `response_A` y `response_B` como iguales.

- `inference_error`: número de juicios que no se han podido evaluar adecuadamente.
- `inference_error_stderr`: error estándar de errores de inferencia en todos los juicios.
- `score`: puntuación global basada en aciertos de pasadas hacia adelante y hacia atrás para `response_B`.
- `score_stderr`: error estándar de puntuación global en juicios por pares.
- `winrate`: probabilidad de que se prefiera `response_B` a `response_A` calculada utilizando probabilidad de Bradley-Terry.
- `lower_rate`: límite inferior (percentil 2,5) de la tasa de aciertos estimada a partir del muestreo de inicio.

Configuración de inferencias

A continuación se ofrece una configuración de inferencia y una explicación de los parámetros que intervienen. Todos los parámetros son opcionales.

```
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`: número máximo de tokens que se generarán. Debe ser un número entero.
- `top_k`: número de tokens de mayor probabilidad que se deben tener en cuenta. Debe ser un número entero.
- `top_p`: umbral de probabilidad acumulada para el muestreo de tokens. Debe ser un valor flotante entre 0,0 and 1,0, ambos inclusive.
- `temperature`: asignación al azar en selección de tokens. Los valores más altos introducen más asignación al azar. Use 0 para hacer que los resultados sean deterministas. Este valor debe ser flotante con un mínimo de 0.
- `top_logprobs`: el número de probabilidades logarítmicas principales que se devolverán en la respuesta de inferencia. El valor debe ser un número entero entre 0 y 20. Las probabilidades logarítmicas contienen los tokens resultantes considerados y las probabilidades de registro de cada token resultante devuelto en el contenido del mensaje.

- `reasoning_effort`: controla el comportamiento de razonamiento de los modelos capaces de razonar. Establezca `reasoning_effort` solo cuando `model_type` especifique un modelo con capacidad de razonamiento (actualmente, `amazon.nova-2-lite-v1:0:256k`). Las opciones disponibles son `null` (valor predeterminado si no se establece ninguno; desactiva el razonamiento), `low` o `high`.

Tenga en cuenta que para `humaneval` recomendamos la siguiente configuración de inferencia:

```
inference:
  top_k: 1
  max_new_tokens: 1600
  temperature: 0.0
```

Configuración de MLflow

A continuación se ofrece una configuración de MLFlow y una explicación de los parámetros que intervienen. Todos los parámetros son opcionales.

```
run:
  mlflow_tracking_uri: ""
  mlflow_experiment_name: ""
  mlflow_run_name: ""
```

- `mlflow_tracking_uri`: (opcional) La ubicación del servidor de seguimiento de MLflow (solo se necesita en SMHP)
- `mlflow_experiment_name`: (opcional) Nombre del experimento para agrupar los procesamientos de ML relacionados
- `mlflow_run_name`: (opcional) nombre personalizado para un entrenamiento específico realizado dentro de un experimento

Ejemplos de fórmula de evaluación

Amazon Nova proporciona cuatro tipos de fórmulas de evaluación, que están disponibles en el repositorio de fórmulas de SageMaker HyperPod en GitHub.

Fórmulas de referencia de texto general

Estas fórmulas le permiten evaluar las capacidades fundamentales de los modelos de Amazon Nova a través de un amplio conjunto de referencias solo de texto. Se proporcionan en formato `xxx_general_text_benchmark_eval.yaml`.

Fórmulas de referencia de uso de conjunto de datos propio

Estas fórmulas le permiten utilizar su propio conjunto de datos como referencia y comparar las salidas del modelo con las respuestas de referencia utilizando diferentes tipos de métricas. Se proporcionan en formato `xxx_bring_your_own_dataset_eval.yaml`.

Estos son los requisitos para utilizar un conjunto de datos propio:

- Requisitos de formato de archivo
 - Debe incluir un único archivo `gen_qa.jsonl` que contenga ejemplos de evaluación.
 - El conjunto de datos debe cargarse en una ubicación de S3 a la que pueda acceder el trabajo de entrenamiento de SageMaker.
 - El archivo debe seguir el formato de esquema requerido para un conjunto de datos general de preguntas y respuestas.
- Requisitos de formato de esquema: cada línea del archivo JSONL debe ser un objeto JSON con los siguientes campos:
 - `query`: (obligatorio) cadena que contiene la pregunta o la instrucción que necesita una respuesta
 - `response`: (obligatorio) cadena que contiene la salida esperada del modelo
 - `system`: (opcional) cadena que contiene la petición del sistema que establece el comportamiento, el rol o la personalidad del modelo de IA antes de que procese la consulta
 - `metadata`: (opcional) Cadena que contiene los metadatos asociados a la entrada con fines de etiquetado.

Esta es una entrada de ejemplo de uso del conjunto de datos propio

```
{
  "system": "You are a english major with top marks in class who likes to give minimal word responses: ",
  "query": "What is the symbol that ends the sentence as a question",
  "response": "?"
}
```

```
{
  "system": "You are a pattern analysis specialist that provides succinct answers: ",
  "query": "What is the next number in this series? 1, 2, 4, 8, 16, ?",
  "response": "32"
}
{
  "system": "You have great attention to detail that follows instructions accurately: ",
  "query": "Repeat only the last two words of the following: I ate a hamburger today and it was kind of dry",
  "response": "of dry"
}
```

Para usar un conjunto de datos personalizado, modifique la fórmula de evaluación con los siguientes campos obligatorios, sin cambiar ningún contenido:

```
evaluation:
  task: gen_qa
  strategy: gen_qa
  metric: all
```

Se aplican las siguientes restricciones:

- Solo se permite un archivo JSONL por evaluación.
- El archivo debe seguir estrictamente el esquema definido.
- Límite de longitud del contexto: para cada muestra del conjunto de datos, la longitud del contexto (incluidas las peticiones de consulta y del sistema) debe ser inferior a 3500

Fórmulas de referencia de Nova LLM como juez

LLM como juez de Amazon Nova es una característica de evaluación de modelos que permite a los clientes comparar la calidad de las respuestas de un modelo con la respuesta de un modelo de referencia en un conjunto de datos personalizado. Incluye un conjunto de datos con peticiones, respuestas de referencia y respuestas de desafío, y utiliza un modelo de juez de Amazon Nova para proporcionar una métrica de tasa de aciertos basada en la [probabilidad de Bradley-Terry](#) con comparaciones por pares.

Las fórmulas se proporcionan en formato `xxx_llm_judge_eval.yaml`.

Estos son los requisitos del LLM como juez:

- Requisitos de formato de archivo
 - Incluya un solo archivo `llm_judge.jsonl` que contenga ejemplos de evaluación. El nombre de archivo debe ser `llm_judge.jsonl`.
 - El conjunto de datos debe cargarse en una ubicación de S3 a la que pueda acceder [SageMaker AI SageMaker HyperPod con RIG](#).
 - El archivo debe seguir el formato de esquema requerido para el conjunto de datos `llm_judge.jsonl`.
 - El conjunto de datos de entrada debe garantizar que todos los registros tengan una longitud de contexto inferior a 12 000.
- Requisitos de formato de esquema: cada línea del archivo JSONL debe ser un objeto JSON con los siguientes campos:
 - `prompt`: (obligatorio) cadena que contiene la petición de la respuesta generada.
 - `response_A`: cadena que contiene la respuesta de referencia.
 - `response_B`: cadena que contiene la respuesta alternativa que se comparará con la respuesta de referencia.

Esta es una entrada de ejemplo de LLM como juez

```
{
  "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 un conjunto de datos personalizado, modifique la fórmula de evaluación con los siguientes campos obligatorios, sin cambiar ningún contenido:

```
evaluation:
  task: llm_judge
  strategy: judge
  metric: all
```

Se aplican las siguientes restricciones:

- Solo se permite un archivo JSONL por evaluación.
- El archivo debe seguir estrictamente el esquema definido.
- Los modelos de Juez de Amazon Nova son iguales en todas las especificaciones de familias de modelos (es decir, Lite, Micro y Pro).
- No se admiten modelos de juez personalizados en este momento.
- Límite de longitud del contexto: para cada muestra del conjunto de datos, la longitud del contexto (incluidas las peticiones de consulta y del sistema) debe ser inferior a 7000

LLM como juez de Nova de fórmulas de referencia multimodales (imágenes)

LLM como juez de Nova (también denominado MM_LLM como juez de Amazon Nova) para entradas multimodales (imágenes) es una característica de evaluación del modelo que le permite comparar la calidad de las respuestas de un modelo con las respuestas de un modelo de referencia mediante un conjunto de datos personalizado. Acepta un conjunto de datos que contiene peticiones, respuestas de línea de base y respuestas de desafío, así como imágenes en forma de cadena codificada en Base64. A continuación, utiliza un modelo de juez de Amazon Nova para proporcionar una métrica de tasa de aciertos basada en la probabilidad de [Bradley-Terry](#) con comparaciones por pares. Formato de fórmula: `xxx_mm_llm_judge_eval.yaml`.

Requisitos del conjunto de datos de Nova LLM

Formato de archivo:

- Archivo `mm_llm_judge.jsonl` único que contiene ejemplos de evaluación. El nombre de archivo debe ser `llm_judge.jsonl`.
- Debe cargar el conjunto de datos en una ubicación de S3 a la que pueda acceder Trabajos de entrenamiento de SageMaker.
- El archivo debe seguir el formato de esquema requerido para el conjunto de datos `mm_llm_judge`.
- El conjunto de datos de entrada debe garantizar que todos los registros tengan una longitud de contexto inferior a 12 000, sin incluir el atributo de la imagen.

Formato de esquema: cada línea del archivo `.jsonl` debe ser un objeto JSON con los siguientes campos.

- Campos obligatorios.

`prompt`: cadena que contiene la petición de la respuesta generada.

`images`: matriz que contiene una lista de objetos con atributos de datos (los valores son cadenas de imágenes codificadas en Base64).

`response_A`: cadena que contiene la respuesta de referencia.

`response_B`: cadena que contiene la respuesta alternativa que se comparará con la respuesta de referencia.

Ejemplo de entrada

Para facilitar la lectura, el siguiente ejemplo incluye nuevas líneas e indentaciones, pero en el conjunto de datos real, cada registro debe estar en una sola línea.

```
{
  "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 un conjunto de datos personalizado, modifique la fórmula de evaluación con los siguientes campos obligatorios, sin cambiar ningún contenido:

```
evaluation:
  task: mm_llm_judge
  strategy: judge
  metric: all
```

Limitaciones

- Solo se permite un archivo `.jsonl` por evaluación.
- El archivo debe seguir estrictamente el esquema definido.
- Los modelos MM como juez de Nova solo admiten referencias de imagen.
- Los modelos juez de Nova son los mismos en todas las especificaciones de Amazon Nova Lite.
- Actualmente no se admiten modelos de juez personalizados.
- No se admite el URI de imagen de Amazon S3.
- El conjunto de datos de entrada debe garantizar que todos los registros tengan una longitud de contexto inferior a 12 000, sin incluir los atributos de imagen.

Juez basado en rúbricas

Rubric Judge es un modelo de evaluación mejorado de LLM como juez basado en Amazon Nova 2.0 Lite. A diferencia del [modelo juez original](#), que solo ofrece veredictos preferenciales (A > B, B > A o empate), Rubric Judge genera de forma dinámica criterios de evaluación personalizados adaptados a cada petición y puntúa de forma detallada varias dimensiones.

Capacidades clave:

- Generación dinámica de criterios: crea automáticamente las dimensiones de evaluación correspondientes en función de la petición de entrada.
- Puntuación ponderada: asigna ponderaciones de importancia a cada criterio para reflejar su importancia relativa.
- Evaluación granular: proporciona puntuaciones detalladas para cada criterio en formato binario (verdadero/falso) o en escala (del 1 al 5).
- Métricas de calidad: calcula las puntuaciones de calidad continuas (escala del 0 al 1) que cuantifican la magnitud de las diferencias entre las respuestas.

Ejemplo de criterio generado por el modelo:

```
price_validation:
  description: "The response includes validation to ensure price is a positive value."
  type: "scale"
  weight: 0.3
```

El modelo evalúa ambas respuestas en función de todos los criterios generados y, a continuación, utiliza estas puntuaciones por criterio para fundamentar su preferencia final.

Temas

- [Configuración de fórmulas](#)
- [Formato del conjunto de datos de entrada](#)
- [Resultado de la evaluación](#)
- [Compatibilidad con el modelo de razonamiento](#)

Configuración de fórmulas

Fórmula de Rubric Judge

Active Rubric Judge configurando task: `rubric_llm_judge` en su 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 del modelo LLM como juez original (a modo de comparación)

El modelo juez original utiliza 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 del conjunto de datos de entrada

El formato del conjunto de datos de entrada es idéntico al [modelo juez original](#):

Campos obligatorios:

- **prompt**: cadena que contiene la petición de entrada y las instrucciones.
- **response_A**: cadena que contiene la salida del modelo de referencia.
- **response_B**: cadena que contiene la salida del modelo personalizado.

Conjunto de datos de ejemplo (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 debe ser un objeto JSON de una sola línea.
- Separe las entradas con saltos de línea.
- Siga la nomenclatura exacta de los campos como se muestra en los ejemplos.

Resultado de la evaluación

Estructura de salida

Rubric Judge genera métricas de evaluación mejoradas en comparación con el modelo juez original:

```
{
  "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"
}
}

```

Nuevas métricas en Rubric Judge

Las siguientes seis métricas son exclusivas de Rubric Judge y proporcionan una evaluación de la calidad pormenorizada:

Métrica	Descripción
<code>weighted_score_A</code>	Puntuación media de calidad normalizada de <code>response_A</code> considerando todos los criterios de evaluación producidos por el modelo. Las puntuaciones se ponderan según la importancia del criterio y se normalizan en una escala del 0 al 1 (cuanto más alta, mayor calidad).
<code>weighted_score_A_stderr</code>	Error estándar de la media de <code>weighted_score_A</code> , que indica incertidumbre estadística.

Métrica	Descripción
<code>weighted_score_B</code>	Puntuación media de calidad normalizada de <code>response_B</code> considerando todos los criterios de evaluación producidos por el modelo. Las puntuaciones se ponderan según la importancia del criterio y se normalizan en una escala del 0 al 1 (cuanto más alta, mayor calidad).
<code>weighted_score_B_stderr</code>	Error estándar de la media de <code>weighted_score_B</code> , que indica incertidumbre estadística.
<code>score_margin</code>	Diferencia entre las puntuaciones ponderadas (calculadas como <code>weighted_score_A - weighted_score_B</code>). Rango: del -1,0 al 1,0. Positivo = <code>response_A</code> es mejor; negativo = <code>response_B</code> es mejor; cercano a cero = calidad similar.
<code>score_margin_stderr</code>	Error estándar de la media de <code>score_margin</code> , que indica incertidumbre en la medición de la diferencia de calidad.

Explicación de las métricas de puntuación ponderada

Objetivo: las puntuaciones ponderadas proporcionan mediciones de calidad continuas que complementan los veredictos sobre preferencias binarias, lo que permite entender en mayor profundidad el rendimiento del modelo.

Diferencias clave con respecto al juez original:

- Juez original: solo genera preferencias discretas ($A > B$, $B > A$, $A = B$).
- Rubric Judge: genera tanto las preferencias como las puntuaciones de calidad continuas (escala del 0 al 1) en función de criterios personalizados.

Interpretación de `score_margin`:

- `score_margin = -0.128`: `Response_B` obtuvo 12,8 puntos porcentuales más que `Response_A`

- $|\text{score\_margin}| < 0.1$: diferencia mínima de calidad (decisión ajustada)
- $|\text{score\_margin}| > 0.2$: diferencia de calidad clara (decisión segura)

Casos de uso:

- Mejora del modelo: identifique las áreas específicas en las que el modelo tiene un rendimiento inferior.
- Cuantificación de la calidad: calcule la magnitud de las brechas de rendimiento, no solo las tasas de ganancias y pérdidas.
- Evaluación de la confianza: distinga entre decisiones ajustadas y claras diferencias de calidad.

Important

Los veredictos finales siguen basándose en las etiquetas de preferencia explícitas del modelo juez para preservar el razonamiento holístico y garantizar una adecuada mitigación de los sesgos de posición mediante una evaluación prospectiva o retrospectiva. Las puntuaciones ponderadas sirven como herramientas de observabilidad, no como sustitutos del veredicto principal.

Metodología de cálculo

Las puntuaciones ponderadas se calculan mediante el siguiente proceso:

- Extracción de los datos de los criterios: analice el resultado YAML del juez para extraer las puntuaciones y las ponderaciones de los criterios.
- Normalización de las puntuaciones:
 - criterios puntuados en una escala del 1 al 5; se normalizan a valores entre 0 y 1 mediante el cálculo $(\text{score} - 1) / 4$.
 - Criterios binarios (true/false): se convierten en 1,0/0,0.
- Aplicación de las ponderaciones: multiplique cada puntuación normalizada por la ponderación del criterio.
- Suma: sume todas las puntuaciones ponderadas de cada respuesta.
- Cálculo del margen: calcule $\text{score\_margin} = \text{weighted\_score\_A} - \text{weighted\_score\_B}$.

Ejemplo: si la suma ponderada de `response_A` da como resultado 0,65 y la de `response_B`, 0,78, el `score_margin` sería -0,13, lo que indica que la calidad de `response_B` es 13 puntos porcentuales superior en todos los criterios ponderados.

Compatibilidad con el modelo de razonamiento

La compatibilidad con el modelo de razonamiento permite la evaluación con modelos de Amazon Nova capaces de razonar que efectúan un razonamiento interno explícito antes de generar las respuestas finales. Esta característica utiliza el control de la API mediante el parámetro `reasoning_effort` para activar o desactivar de forma dinámica la funcionalidad de razonamiento, lo que podría mejorar la calidad de la respuesta en tareas analíticas complejas.

Modelos compatibles:

- `amazon.nova-2-lite-v1:0:256k`

Configuración de fórmulas

Active el razonamiento agregando el parámetro `reasoning_effort` a la sección `inference` de su 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                                         # [MODIFIABLE] Sampling
temperature (0 = deterministic)
```

Uso del parámetro reasoning_effort

El parámetro reasoning_effort controla el comportamiento de razonamiento de los modelos con capacidad de razonamiento.

Requisitos previos:

- Compatibilidad del modelo: establezca reasoning_effort solo cuando model_type especifique un modelo con capacidad de razonamiento (actualmente, amazon.nova-2-lite-v1:0:256k).
- Gestión de errores: si se utiliza reasoning_effort con modelos no compatibles, se producirá un error: ConfigValidationError: "Reasoning mode is enabled but model '{model_type}' does not support reasoning. Please use a reasoning-capable model or disable reasoning mode."

Opciones disponibles:

Opción	Comportamiento	Límite de tokens	Caso de uso
null (por defecto)	Desactiva el modo de razonamiento	N/A	Evaluación estándar sin sobrecarga de razonamiento
low	Permite razonar con restricciones	4000 tokens para el razonamiento interno	Escenarios que requieren un razonamiento conciso; optimiza para

Opción	Comportamiento	Límite de tokens	Caso de uso
			una mayor velocidad y rentabilidad
high	Permite razonar sin restricciones	El razonamiento interno no tiene un límite de tokens	Problemas complejos que requieren un análisis exhaustivo y un razonamiento paso a paso

¿Cuándo habilitar el razonamiento?

Utilice el modo de razonamiento (**low**, **medium** o **high**) en estos casos:

- Tareas complejas de resolución de problemas (matemáticas, acertijos de lógica, programación).
- Preguntas analíticas de varios pasos que requieran un razonamiento intermedio.
- Tareas en las que las explicaciones detalladas o el pensamiento paso a paso mejoren la precisión.
- Escenarios en los que se dé prioridad a la calidad de la respuesta por encima de la velocidad.

Utilice el modo sin razonamiento (omita el parámetro) en estos casos:

- Preguntas y respuestas sencillas o consultas fácticas.
- Tareas de escritura creativa.
- Tareas en las que los tiempos de respuesta más rápidos sean fundamentales.
- Evaluación comparativa del rendimiento, en la que debe excluirse la sobrecarga de razonamiento.
- Priorización de la rentabilidad cuando el razonamiento no mejore el rendimiento de la tarea.

Solución de problemas

Error: "Reasoning mode is enabled but model does not support reasoning"

Causa: el parámetro `reasoning_effort` está establecido en un valor que no es null, pero el valor especificado para `model_type` no admite el razonamiento.

Solución:

- Compruebe que el tipo de modelo sea `amazon.nova-2-lite-v1:0:256k`.
- Si utiliza un modelo diferente, cámbielo a un modelo que pueda razonar o elimine el parámetro `reasoning_effort` de la fórmula

Inicio de un trabajo de evaluación

A continuación se ofrece una sugerencia de configuración del tipo de instancia y del tipo de modelo de evaluación:

```
# 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]

```

También debería poder ver el estado del trabajo a través de la consola de clúster de Amazon EKS.

Acceso y análisis de los resultados de la evaluación

Una vez que el trabajo de evaluación haya finalizado satisfactoriamente, podrá acceder a los resultados y analizarlos utilizando la información de esta sección. En función de la `output_s3_path` (por ejemplo, `s3://output_path/`) definida en la fórmula, la estructura de salida es la siguiente:

```

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]

```

Los resultados de las métricas se almacenan en la ubicación de salida de S3 especificada `s3://output_path/job_name/eval-result/result-timestamp.json`.

Los resultados de Tensorboard se almacenan en la ruta de S3 `s3://output_path/job_name/eval-tensorboard-result/eval/event.out.tfevents.epoch+ip`.

Todos los resultados de inferencia, excepto `llm_judge` y `strong_reject`, se almacenan en la ruta de S3: `s3://output_path/job_name/eval-result/details/model/taskname.parquet`.

Para `gen_qa`, el archivo `inference_output.jsonl` contiene los siguientes campos para cada objeto JSON:

- `petición`: última petición enviada al modelo
- `inferencia`: salida de inferencia sin procesar del modelo
- `gold`: la respuesta objetivo del conjunto de datos de entrada
- `metadata`: la cadena de metadatos del conjunto de datos de entrada, si se proporciona

Para visualizar las métricas de evaluación en Tensorboard, siga estos pasos:

1. Navegue hasta SageMaker AI Tensorboard.
2. Seleccione Carpetas de S3.
3. Agregue la ruta de la carpeta de S3, por ejemplo `s3://output_path/job-name/eval-tensorboard-result/eval`.
4. Espere a que se complete la sincronización.

Hay disponibles series temporales, escalares y visualizaciones de texto.

Recomendamos que siga las siguientes prácticas recomendadas:

- Mantenga las rutas de salida organizadas por modelo y tipo de referencia.
- Mantenga convenciones de nomenclatura coherentes para facilitar el seguimiento.
- Guarde los resultados extraídos en un lugar seguro.
- Supervise el estado de sincronización de TensorBoard para que los datos se carguen correctamente.

Los registros de errores de trabajo de SageMaker HyperPod se encuentran en el grupo de registro de CloudWatch `/aws/sagemaker/Clusters/cluster-id`.

Formato de salida de la probabilidad logarítmica

Cuando `top_logprobs` se configura en los ajustes de inferencia, el resultado de la evaluación incluye las probabilidades logarítmicas del token en los archivos de parquet. Cada posición de un token contiene un diccionario de los principales tokens candidatos con sus probabilidades logarítmicas siguiendo esta estructura:

```
{
  "Ġint": {"logprob_value": -17.8125, "decoded_value": " int"},
  "Ġthe": {"logprob_value": -2.345, "decoded_value": " the"}
}
```

Cada entrada de token contiene lo siguiente:

- `logprob_value`: el valor de probabilidad logarítmica del token
- `decoded_value`: la representación en cadena decodificada legible por humanos del token

El token tokenizador sin procesar se utiliza como clave del diccionario para garantizar la exclusividad, mientras que `decoded_value` proporciona una interpretación legible.

Evaluación del RFT

Note

La evaluación mediante funciones de recompensas remotas en su propio entorno de AWS solo está disponible si es cliente de Amazon Nova Forge.

Important

El campo de configuración `rl_env` se utiliza exclusivamente para la evaluación, no para el entrenamiento. Durante el entrenamiento, las funciones de recompensas se configuran mediante una infraestructura `reward_lambda_arn` (de turno único) o `BYOO rollout.delegate: true` (de varios turnos).

¿Qué es la evaluación del RFT?

La evaluación del RFT le permite evaluar el rendimiento del modelo mediante funciones de recompensas personalizadas antes, durante o después del entrenamiento de aprendizaje por refuerzo. A diferencia de las evaluaciones estándar que utilizan métricas predefinidas, la evaluación del RFT le permite definir sus propios criterios de éxito mediante una función de Lambda que puntúa los resultados del modelo en función de sus requisitos específicos.

¿Por qué se debe evaluar con el RFT?

La evaluación es crucial para determinar si el proceso de refinamiento de RL:

- Ha mejorado la alineación del modelo con su caso de uso específico y sus valores humanos.
- Ha mantenido o mejorado las capacidades del modelo en tareas clave.
- Ha evitado efectos secundarios no deseados, como la reducción de la objetividad, el aumento de los detalles o la degradación del rendimiento en otras tareas.
- Ha cumplido con los criterios de éxito personalizados, tal como los define su función de recompensas.

¿Cuándo se debe utilizar la evaluación del RFT?

Utilice la evaluación del RFT en los siguientes escenarios:

- Antes del entrenamiento RFT: establezca métricas de línea de base en su conjunto de datos de evaluación.
- Durante el entrenamiento RFT: supervise el progreso del entrenamiento con puntos de control intermedios.
- Después del entrenamiento RFT: valide que el modelo final cumpla con sus requisitos.
- Comparación de modelos: evalúe varias versiones del modelo con criterios de recompensa coherentes.

Note

Utilice la evaluación del RFT cuando necesite métricas personalizadas y específicas de un dominio. Para una evaluación de uso general (precisión, perplejidad, BLEU), utilice métodos de evaluación estándar.

Temas

- [Requisitos del formato de los datos](#)
- [Preparación de la fórmula de evaluación](#)
- [Funciones de recompensas predefinidas](#)
- [Creación de la función de recompensas](#)
- [Permisos de IAM](#)
- [Ejecución del trabajo de evaluación](#)
- [Descripción de los resultados de la evaluación](#)

Requisitos del formato de los datos

Estructura de los datos de entrada

Los datos de entrada de la evaluación del RFT deben seguir el formato de refinamiento por refuerzo de OpenAI. Cada ejemplo es un objeto JSON que contiene lo siguiente:

- `messages`: matriz de turnos conversacionales con los roles `system` y `user`
- Otros metadatos opcionales, por ejemplo, `reference_answer`

Ejemplo de formato de datos

En el siguiente ejemplo se muestra el formato obligatorio:

```
{
  "messages": [
    {
      "role": "user",
      "content": [
        {
          "type": "text",
          "text": "Solve for x. Return only JSON like {\"x\": <number>}. Equation: 2x + 5 = 13"
        }
      ]
    }
  ],
  "reference_answer": {
    "x": 4
  }
}
```

Limitaciones actuales

Las siguientes limitaciones se aplican a la evaluación del RFT:

- Solo texto: no se admiten entradas multimodales (imágenes, audio, video).
- Conversaciones de turno único: solo admite mensajes de un solo usuario (no se admiten diálogos de varios turnos).
- Formato JSON: los datos de entrada deben estar en formato JSONL (un objeto JSON por línea).
- Resultados del modelo: la evaluación se lleva a cabo en las terminaciones generadas a partir del modelo especificado.

Preparación de la fórmula de evaluación

Configuración de fórmula de muestra

En el siguiente ejemplo se muestra una fórmula de evaluación del RFT completa:

```
run:
  name: nova-lite-rft-eval-job
  model_type: amazon.nova-lite-v1:0:300k
  model_name_or_path: s3://escrow_bucket/model_location      # [MODIFIABLE] S3 path to
your model or model identifier
  replicas: 1                                                # [MODIFIABLE] For SageMaker
Training jobs only; fixed for SageMaker HyperPod jobs
  data_s3_path: ""                                           # [REQUIRED FOR HYPERPOD]
Leave empty for SageMaker Training jobs
  output_s3_path: ""                                         # [REQUIRED] Output artifact
S3 path for evaluation results

evaluation:
  task: rft_eval                                             # [FIXED] Do not modify
  strategy: rft_eval                                         # [FIXED] Do not modify
  metric: all                                                 # [FIXED] Do not modify

# Inference Configuration
inference:
  max_new_tokens: 8196                                       # [MODIFIABLE] Maximum tokens
to generate
  top_k: -1                                                  # [MODIFIABLE] Top-k sampling
parameter
  top_p: 1.0                                                 # [MODIFIABLE] Nucleus
sampling parameter
```

```

temperature: 0 # [MODIFIABLE] Sampling
temperature (0 = deterministic)
top_logprobs: 0

# Evaluation Environment Configuration (NOT used in training)
rl_env:
  reward_lambda_arn: arn:aws:lambda:<region>:<account_id>:function:<reward-function-name>

```

Funciones de recompensas predefinidas

Hay dos funciones de recompensas predefinidas (`prime_code` y `prime_math`) disponibles como capa de Lambda para una integración fácil con las funciones de Lambda del RFT.

Descripción general

Estas funciones predefinidas ofrecen capacidades de evaluación listas para usar para:

- `prime_code`: generación de código y evaluación de la corrección
- `prime_math`: evaluación del razonamiento matemático y la resolución de problemas

Configuración rápida

Para usar funciones de recompensas predefinidas:

1. Descargue la capa de Lambda de las [versiones de nova-custom-eval-sdk](#).
2. Publique la capa de Lambda mediante la 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. Agregue la capa a la función de Lambda en la consola de AWS (seleccione `preset-function-layer` en la capa personalizada y agregue también `AWSSDKPandas-Python312` para dependencias de NumPy).
4. Impórtela y úsela en el código de Lambda:

```

from prime_code import compute_score # For code evaluation

```

```
from prime_math import compute_score # For math evaluation
```

Función prime_code

Propósito: evalúa las tareas de generación de código de Python mediante la ejecución del código en casos de prueba y la medición de la corrección.

Ejemplo de formato de conjunto de datos de entrada de la evaluación:

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

Características clave:

- Extracción automática de código de bloques de código Markdown
- Detección de funciones y pruebas basadas en llamadas
- Ejecución de casos de prueba con protección de tiempo de espera
- Comprobaciones de compilación y validación de la sintaxis
- Informes de errores detallados con rastreos

Función prime_math

Propósito: evalúa el razonamiento matemático y las capacidades de resolución de problemas con soporte matemático simbólico.

Formato de entrada:

```
{"messages":[{"role":"user","content":"What is the derivative of x^2 + 3x?."}], "reference_answer":"2*x + 3"}
```

Características clave:

- Evaluación matemática simbólica con SymPy
- Múltiples formatos de respuesta (LaTeX, texto sin formato, simbólico)

- Comprobación de equivalencia matemática
- Normalización y simplificación de expresiones

Prácticas recomendadas

Siga estas prácticas recomendadas cuando use funciones de recompensa predefinidas:

- Utilice los tipos de datos adecuados en los casos de prueba (números enteros frente a cadenas, valores booleanos frente a “verdaderos”).
- Proporcione firmas de funciones claras en los problemas de código.
- Incluya casos extremos en las entradas de prueba (cero, números negativos, entradas vacías).
- Formatee las expresiones matemáticas de forma coherente en las respuestas de referencia.
- Pruebe la función de recompensas con datos de ejemplo antes de la implementación.

Creación de la función de recompensas

ARN de Lambda

Debe consultar el siguiente formato para el ARN de Lambda:

```
"arn:aws:lambda:*:*:function:*SageMaker*"
```

Si Lambda no tiene este esquema de nombres, el trabajo fallará y mostrará este error:

```
[ERROR] Unexpected error: lambda_arn must contain one of: ['SageMaker', 'sagemaker', 'Sagemaker'] when running on SMHP platform (Key: lambda_arn)
```

Estructura de la función de Lambda

La función de Lambda recibe lotes de salidas del modelo y devuelve las puntuaciones de recompensas. A continuación se muestra un ejemplo de implementación:

```
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 la solicitud de Lambda

La función de Lambda recibe datos en este formato:

```

[
  {
    "id": "sample-001",

```

```

"messages": [
  {
    "role": "user",
    "content": [
      {
        "type": "text",
        "text": "Do you have a dedicated security team?"
      }
    ]
  },
  {
    "role": "nova_assistant",
    "content": [
      {
        "type": "text",
        "text": "As an AI developed by Company, I don't have a dedicated security
team in the traditional sense. However, the development and deployment of AI systems
like me involve extensive security measures, including data encryption, user privacy
protection, and other safeguards to ensure safe and responsible use."
      }
    ]
  }
],
"reference_answer": {
  "compliant": "No",
  "explanation": "As an AI developed by Company, I do not have a traditional
security team. However, the deployment involves stringent safety measures, such as
encryption and privacy safeguards."
}
}
]

```

Note

La estructura del mensaje incluye la matriz content anidada, que coincide con el formato de datos de entrada. El último mensaje con el rol nova_assistant contiene la respuesta generada por el modelo.

Formato de la respuesta de Lambda

La función de Lambda debe devolver datos en este 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 la respuesta

- `id`: debe coincidir con el ID de muestra de entrada
- `aggregate_reward_score`: puntuación general (normalmente de 0,0 a 1,0)
- `metrics_list`, matriz de métricas individuales con:
 - `name`: identificador de la métrica (por ejemplo, “precisión”, “fluidez”)
 - `value`: puntuación de la métrica (normalmente de 0,0 a 1,0)
 - `type`: “Métrica” (para informes) o “Recompensa” (utilizada en el entrenamiento)

Permisos de IAM

Permisos necesarios

El rol de ejecución de SageMaker AI debe tener permisos para invocar la función de Lambda. Agregue esta política al rol de ejecución de SageMaker AI:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
```

```
    "Action": [
      "lambda:InvokeFunction"
    ],
    "Resource": "arn:aws:lambda:region:account-id:function:function-name"
  }
]
```

Rol de ejecución de Lambda

El rol de ejecución de una función de Lambda necesita permisos de ejecución de Lambda básicos:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "logs:CreateLogGroup",
        "logs:CreateLogStream",
        "logs:PutLogEvents"
      ],
      "Resource": "arn:aws:logs:*:*:*"
    }
  ]
}
```

Permisos adicionales: si la función de Lambda accede a otros servicios de AWS (por ejemplo, Amazon S3 para los datos de referencia o DynamoDB para el registro), agregue esos permisos al rol de ejecución de Lambda.

Ejecución del trabajo de evaluación

1. Preparar los datos

- Formatee los datos de evaluación de acuerdo con los requisitos de formato de los datos.
- Cargue el archivo JSONL en Amazon S3: `s3://your-bucket/eval-data/eval_data.jsonl`.

2. Configuración de la fórmula

Actualice la fórmula de muestra con su configuración:

- Establezca `model_name_or_path` en la ubicación del modelo.
- Establezca `lambda_arn` en el ARN de la función de recompensas.
- Establezca `output_s3_path` en la ubicación de salida deseada.
- Ajuste los parámetros de `inference` según sea necesario.

Guarde la fórmula como `rft_eval_recipe.yaml`.

3. Ejecución de la evaluación

Ejecute el trabajo de evaluación con el cuaderno proporcionado: [cuaderno de evaluación del modelo de Nova](#).

4. Supervise el progreso

Supervise el trabajo de evaluación con las siguientes herramientas:

- Consola de SageMaker AI: compruebe el estado y los registros de los trabajos.
- Registros de CloudWatch: consulte los registros de ejecución detallados.
- Registros de Lambda: depure problemas de la función de recompensas.

Descripción de los resultados de la evaluación

Formato de salida

El trabajo de evaluación envía los resultados a la ubicación de Amazon S3 especificada en formato JSONL. Cada línea contiene los resultados de la evaluación de una muestra:

```
{
  "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

El resultado del trabajo de evaluación del RFT es idéntico al formato de la respuesta de Lambda. El servicio de evaluación analiza la respuesta de la función de Lambda sin modificaciones, lo que garantiza la coherencia entre los cálculos de recompensas y los resultados finales.

Interpretación de los resultados

Puntuación total de recompensas:

- Rango: normalmente de 0,0 (peor) a 1,0 (mejor), pero depende de la implementación
- Propósito: un solo número que resume el rendimiento general
- Uso: comparación de modelos, seguimiento de las mejoras con respecto al entrenamiento

Métricas individuales:

- Tipo de métrica: métricas informativas para el análisis
- Tipo de recompensa: métricas utilizadas durante el entrenamiento RFT
- Interpretación: unos valores más altos suelen indicar un mejor rendimiento (a menos que diseñe métricas inversas)

Puntos de referencia de rendimiento

Lo que constituye un rendimiento “bueno” depende de su caso de uso:

Intervalo de puntuación	Interpretación	Action
Entre 0,8 y 1,0	Excelente	Modelo listo para su implementación

Intervalo de puntuación	Interpretación	Action
Entre 0,6 y 0,8	Buena	Podría beneficiarse de mejoras menores
Entre 0,4 y 0,6	Regular	Necesita una mejora importante
Entre 0,0 y 0,4	Deficiente	Revisión de los datos de entrenamiento y de la función de recompensas

Important

Estas son unas directrices generales. Defina sus propios umbrales en función de los requisitos empresariales, el rendimiento básico del modelo, las restricciones específicas del dominio y el análisis de la relación entre costo y beneficio del entrenamiento continuo.

Supervisión de los trabajos de HyperPod con MLFlow

Puede utilizar MLflow para hacer un seguimiento y supervisar sus trabajos de entrenamiento en SageMaker HyperPod. Siga estos pasos para configurar MLflow y conectarlo a sus fórmulas de entrenamiento.

Cree la aplicación MLflow

Comando AWS CLI de ejemplo

```
aws sagemaker-mlflow create-mlflow-app \
  --name <app-name> \
  --artifact-store-uri <s3-bucket-name> \
  --role-arn <role-arn> \
  --region <region-name>
```

Ejemplo de resultado

```
{
  "Arn": "arn:aws:sagemaker:us-east-1:111122223333:mlflow-app/app-LGZE0Z2UY4NZ"
```

```
}
```

Genere la URL prefirrada

Comando AWS CLI de ejemplo

```
aws sagemaker-mlflow create-presigned-mlflow-app-url \  
  --arn <app-arn> \  
  --region <region-name> \  
  --output text
```

Ejemplo de resultado


```
https://app-LGZE0Z2UY4NZ.mlflow.sagemaker.us-east-1.app.aws/auth?  
authToken=eyJhbGciOiJIUzI1NiJ9.eyJhdXRoVG9rZW5JZCI6IkxETVBPUyIsImZhc0NyZWRLbnRpYWxzIjoiQWdWNGhD
```

Abra la URL prefirrada y visualícela la aplicación

Click

```
https://app-LGZE0Z2UY4NZ.mlflow.sagemaker.us-east-1.app.aws/auth?  
authToken=eyJhbGciOiJIUzI1NiJ9.eyJhdXRoVG9rZW5JZCI6IkxETVBPUyIsImZhc0NyZWRLbnRpYWxzIjoiQWdWNGhD
```

Visualización



Pásela a la fórmula en el bloque de puesta en marcha de su fórmula de SageMaker HyperPod


Fórmula

```
run
```



```
mlflow_tracking_uri: arn:aws:sagemaker:us-east-1:111122223333:mlflow-app/app-LGZE0Z2UY4NZ
```

Visualización



Entrenamiento iterativo

Descripción general

El entrenamiento iterativo es el proceso de refinar repetidamente un modelo realizando varios ciclos de entrenamiento con diferentes métodos de entrenamiento (entrenar, evaluar, analizar errores y ajustar los datos, objetivos o hiperparámetros). Cada ronda comienza desde el punto de control anterior. Este enfoque le permite centrarse sistemáticamente en los modos de error del modelo,

incorporar ejemplos seleccionados que aborden puntos débiles específicos y adaptarse a los requisitos que cambian con el tiempo.

Ventajas en comparación con el entrenamiento de una sola iteración:

- Mejora específica: aborde los patrones de error específicos detectados en la evaluación.
- Perfeccionamiento adaptativo: responda a los cambios de distribución o a la evolución de los requisitos de los productos.
- Mitigación de riesgos: valide las mejoras de forma gradual en lugar de tener que hacer una sola sesión de entrenamiento de larga duración.
- Eficiencia de los datos: centre los esfuerzos de recopilación de datos en las áreas en las que el modelo tenga un rendimiento inferior.
- Formación curricular: haga varias rondas de entrenamiento con datos de cada vez mayor calidad.

Funcionamiento

Ubicación de los puntos de control y acceso

Una vez finalizado cada trabajo de entrenamiento, se genera un archivo de manifiesto en la ubicación de salida especificada por el parámetro `output_path` en la configuración del entrenamiento.

Para acceder al punto de control

- Navegue hasta la `output_path` especificada en S3.
- Descargue y extraiga el archivo `output.tar.gz`.
- Abra el archivo `manifest.json`.
- Localice el parámetro `checkpoint_s3_bucket`, que contiene el URI de S3 de su modelo entrenado.

Ejemplo de la estructura de `manifest.json`

```
{
  "checkpoint_s3_bucket": "s3://customer-escrow-<account-number>-smtj-<unique-
  identifier>/<job-name>/stepID",
  ...
}
```

```
}
```

Explicación de los buckets de custodia

Dado que las ponderaciones de Amazon Nova son exclusivas, los puntos de control de los modelos entrenados se almacenan en buckets de S3 de custodia dentro de las cuentas administradas por AWS, en lugar de copiarlos en su cuenta. Estos buckets de custodia:

- Guardan las ponderaciones de sus modelos personalizados de forma segura.
- Pueden ser consultados por otros servicios de AWS (inferencia, evaluación y posteriores trabajos de entrenamiento).
- Solo pueden ser accedidos por su cuenta de AWS mediante permisos de IAM.
- Incurren en cargos de almacenamiento de S3 estándar en su cuenta (consulte Consideraciones sobre costos).

Puede usar la ruta del bucket de custodia a modo de `model_name_or_path` en su próxima sesión de entrenamiento para continuar con el entrenamiento iterativo.

Uso de puntos de control para el entrenamiento iterativo

Configure su siguiente trabajo de entrenamiento para que use el punto de control anterior como modelo 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
```

Cuándo utilizar el entrenamiento iterativo

Casos de uso ideales

Utilice el entrenamiento iterativo cuando tenga:

- Bucles de retroalimentación: capacidad de recopilar casos de errores del mundo real y abordarlos de manera sistemática.

- Entornos dinámicos: documentación, API o temas de soporte en evolución que requieran actualizaciones periódicas del modelo.
- Evaluación sólida: pruebas comparativas y marcos de evaluación sólidos (consulte los ejemplos a continuación) para medir las mejoras con confianza.
- Capacidad de operaciones de ML: recursos para gestionar varios ciclos de entrenamiento y control de versiones.

Ejemplos de marcos de evaluación sólidos

- Conjuntos de pruebas comparativas automatizadas con umbrales de éxito o error
- Protocolos de evaluación humana con métricas de fiabilidad entre evaluadores
- Escenarios de pruebas de equipo rojo que tratan casos límite y entradas contradictorias
- Infraestructura de pruebas A/B para medir el impacto en la producción

Patrones comunes

Canalización SFT → RFT: un patrón iterativo de uso frecuente implica lo siguiente:

- SFT primero: enseñe al modelo cómo resolver problemas mediante ejemplos de demostración.
- RFT después: optimice el rendimiento en un ámbito más amplio de problemas mediante señales de recompensa.

Este orden es esencial cuando los modelos tienen un rendimiento deficiente al principio: el RFT en modelos de precisión cercana a cero no mejorará el rendimiento sin establecer primero las capacidades básicas de resolución de problemas mediante el SFT.

Cuándo no utilizar el entrenamiento iterativo

Evite el entrenamiento iterativo en los siguientes casos:

- Tareas estables y bien definidas: datos estacionarios con requisitos consistentes que ya lleguen a un rendimiento cercano al máximo.
- Problemas de clasificación sencillos: tareas limitadas en las que basta con una entrenamiento de una sola iteración.
- Limitaciones de recursos: falta de capacidades dedicadas de operaciones de ML para administrar varios ciclos de entrenamiento.

- Ganancias marginales: cuando la sobrecarga no justifique mejoras mínimas en el rendimiento.

Ejemplo de flujo de trabajo: SFT → RFT

Este ejemplo muestra un patrón de entrenamiento iterativo común para los modelos de razonamiento.

Paso 1: entrenamiento inicial con SFT

Configure e inicie el trabajo de entrenamiento con SFT con su conjunto de datos:

```
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
```

Justificación: SFT ofrece demostraciones adicionales que configuran los resultados de los modelos en la voz y el formato deseados, estableciendo las capacidades fundamentales.

Una vez finalizado el entrenamiento

- Anote la `output_path` configurada en su trabajo de entrenamiento.
- Descargue `output.tar.gz` desde esa ubicación.
- Extraiga y busque `manifest.json`.
- Copie el valor `checkpoint_s3_bucket`.

Paso 2: entrenamiento con RFT en el punto de control del SFT

Cree un nuevo trabajo de entrenamiento con RFT utilizando el punto de control del 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>
```

Justificación: el entrenamiento con RFT se basa en el SFT, lo que permite al modelo desarrollar patrones de razonamiento más complejos optimizados por su función de recompensa.

Paso 3: evaluación e iteración

Ponga en marcha la evaluación en el punto de control del RFT para evaluar el rendimiento:

```
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
```

Si las métricas objetivo no se cumplen, continúe iterando con los datos o hiperparámetros ajustados.

Important

La técnica de entrenamiento (LoRA o rango completo) debe permanecer constante en todas las iteraciones:

- Si usa SFT con LoRA, debe usar RFT con LoRA.
- Si usa SFT con rango completo, debe usar RFT con rango completo.
- No puede cambiar entre LoRA y rango completo a mitad del proceso

Important

Si se usa una clave de KMS para el cifrado en el bucket de S3 resultante propiedad de Amazon, se debe usar esa misma clave de KMS en todas las iteraciones futuras.

Supervisión del progreso en las iteraciones

Puede hacer un seguimiento de las métricas mediante MLflow [configurando MLflow](#) para sus trabajos.

Creación de una aplicación MLflow

Uso de la interfaz de usuario de Studio: si crea un trabajo de entrenamiento a través de la interfaz de usuario de Studio, se crea automáticamente una aplicación MLflow predeterminada que se selecciona por defecto en Opciones avanzadas.

Uso de la CLI: si usa la CLI, debe crear una aplicación MLflow y pasarla como entrada a la solicitud de la API del trabajo de entrenamiento.

```
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)
```

Acceso a la aplicación MLflow

Uso de la CLI: cree una URL prefirmada para acceder a la interfaz de usuario de la aplicación MLflow:

```
aws sagemaker create-presigned-mlflow-app-url \
  --arn $mlflow_app_arn \
  --region $region \
  --output text
```

Uso de la interfaz de usuario de Studio: la interfaz de usuario de Studio muestra las métricas clave almacenadas en MLflow y proporciona un enlace a la interfaz de usuario de la aplicación MLflow.

Métricas clave para hacer un seguimiento

Supervise estas métricas en las iteraciones para evaluar la mejora y hacer un seguimiento del progreso del trabajo:

Para SFT

- Curvas de pérdidas de entrenamiento

- Número de muestras consumidas y tiempo de procesamiento
- Precisión del rendimiento en conjuntos de prueba reservados
- Cumplimiento del formato (por ejemplo, velocidad de salida JSON válida)
- Perplejidad en datos de evaluación específicos del dominio

Para RFT

- Puntuaciones promedio de recompensa durante el entrenamiento
- Distribución de las recompensas (porcentaje de respuestas con alta recompensa)
- Tendencias de la recompensa en validación (atención al sobreajuste)
- Tasas de éxito específicas por tarea (por ejemplo, tasa de aprobación en procesamiento de código, precisión en problemas matemáticos)

General

- Diferencias de rendimiento en pruebas comparativas entre iteraciones
- Puntuaciones de evaluación humana en muestras representativas
- Métricas de producción (si se realiza una implementación iterativa)

Cómo determinar cuándo parar

Deje de iterar en los siguientes casos:

- Rendimiento estancado: el entrenamiento adicional ya no mejora significativamente las métricas objetivo
- Cambio de técnica para seguir progresando: si una técnica se estanca, pruebe a cambiarla (por ejemplo, SFT → RFT → SFT) para superar los límites de rendimiento
- Métricas objetivo alcanzadas: se cumplen sus criterios de rendimiento correcto.
- Regresión detectada: las nuevas iteraciones reducen el rendimiento (consulte los procedimientos de reversión que aparecen a continuación)

Para obtener información detallada sobre los procedimientos de evaluación, consulte la sección [Evaluación](#).

Prácticas recomendadas

Comience en pequeño y amplíe poco a poco

Empiece con conjuntos de datos mínimos y épocas de entrenamiento únicas para validar su enfoque antes de escalar verticalmente. Esto genera confianza y permite identificar los problemas de forma temprana.

Establezca métricas de éxito claras

Defina los indicadores cuantitativos y cualitativos antes de empezar:

Ejemplo de métricas de éxito por caso de uso

- Respuesta a la pregunta: precisión de coincidencia exacta, puntuación de F1, puntuaciones de preferencia humana
- Generación de código: tasa de aprobación de las pruebas unitarias, éxito de compilación, tiempo de ejecución
- Tareas de razonamiento: precisión de los pasos, exactitud de la respuesta final, puntuaciones de recompensa
- Generación de contenido: puntuaciones de coherencia, precisión fáctica, adherencia al estilo

Implemente la evaluación automatizada

Configure procesos de evaluación automatizada para hacer un seguimiento del rendimiento después de cada ronda, lo que permitirá una iteración rápida y una comparación objetiva.

Lleve a cabo un control de versiones riguroso

Documente lo siguiente en cada iteración:

- Versiones y modificaciones del conjunto de datos
- Ubicaciones de los puntos de control del modelo
- Cambios en los hiperparámetros
- Métricas de rendimiento y diferencias de rendimiento
- Observaciones cualitativas

Esto crea conocimiento institucional y permite la depuración.

Céntrese en la calidad de datos antes que en la cantidad

Analice los casos de error de rondas anteriores y agregue ejemplos específicos y de alta calidad en lugar de simplemente aumentar el tamaño del conjunto de datos.

Planifique el presupuesto de las iteraciones

Planifique entre 3 y 5 iteraciones como rango habitual:

- Entre 1 y 2 iteraciones: suelen ser suficientes para llevar a cabo mejoras sencillas o para dar los toques finales.
- Entre 3 y 5 iteraciones: adecuadas para tareas complejas que requieren varios ciclos de refinamiento.
- Más de 5 iteraciones: esto puede indicar rendimientos decrecientes o la necesidad de adoptar enfoques distintos.

Ajuste el número en función del presupuesto computacional y las tasas de mejora del rendimiento.

Implemente capacidades de restauración

Si una iteración introduce regresiones, haga lo siguiente:

- Identifique la regresión: compare las métricas de evaluación de los puntos de control.
- Regrese al punto de control anterior: utilice la ruta de S3 del punto de control anterior como `model_name_or_path`.
- Ajuste el enfoque de entrenamiento: modifique los datos, los hiperparámetros o la técnica antes de volver a intentarlo.
- Documente el error: registre la causa de la regresión para evitar que se repita.

Ejemplo de reversión

```
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>"
```

Consideraciones sobre costos

Almacenamiento de puntos de control

- **Ubicación:** los puntos de control almacenados en buckets de custodia incurren en cargos de almacenamiento de S3 estándar que se facturan a su cuenta de AWS.
- **Retención:** los puntos de control se conservan indefinidamente a menos que se eliminen de forma explícita.
- **Administración:** implemente políticas de ciclo de vida para archivar o eliminar los puntos de control antiguos que ya no necesite.

Consejos par optimizar los costos

- Elimine los puntos de control intermedios después de validar las iteraciones más recientes.
- Archive los puntos de control en S3 Glacier para conservarlos a largo plazo a un costo menor.
- Defina políticas de retención en función de sus necesidades de cumplimiento y experimentación.

Limitaciones

Consistencia en la familia de modelos

Al entrenar de forma iterativa, debe usar el mismo tipo de modelo en todas las iteraciones.

Entrenamiento inicial

```
run:
  model_type: amazon.nova-2-lite-v1:0:256k
  model_name_or_path: "nova-lite-2/prod"
```

Las iteraciones posteriores deben usar el mismo `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>"
```

Consistencia en la técnica de entrenamiento

La técnica de entrenamiento debe permanecer constante en todas las iteraciones:

- Los modelos entrenados con LoRA solo se pueden entrenar de forma iterativa con LoRA.
- Los modelos entrenados en rango completo solo se pueden entrenar de forma iterativa en rango completo.

Cómo funcionan los adaptadores LoRA en el entrenamiento iterativo

- Cada iteración de entrenamiento con LoRA genera nuevas ponderaciones de adaptación
- Los adaptadores nuevos sustituyen (no se apilan) a los adaptadores anteriores.
- El modelo base permanece congelado; solo se actualizan los adaptadores.

Matriz de compatibilidad de técnicas

Entrenamiento inicial	Puede iterar con
SFT (rango completo)	SFT (rango completo), RFT (rango completo)
SFT (LoRA)	SFT (LoRA), RFT (LoRA)
RFT (rango completo)	RFT (rango completo)
RFT (LoRA)	RFT (LoRA)

Verificación de la compatibilidad antes de comenzar un trabajo

- Consulte la fórmula de entrenamiento anterior para identificar el tipo de modelo y la técnica de entrenamiento (LoRA o rango completo)
- Asegúrese de que la nueva fórmula coincida tanto con el tipo de modelo como con la técnica
- Revise el archivo manifest.json para confirmar que la ruta del punto de control sea correcta

Solución de problemas

Error: “Incompatible model training techniques detected”

Causa: la técnica de entrenamiento (LoRA o rango completo) no coincide con la técnica del punto de control.

Solución: asegúrese de que la fórmula utilice la misma técnica de entrenamiento que el modelo original:

- Si el punto de control se entrenó con LoRA, use LoRA en la nueva fórmula
- Si el punto de control se entrenó en rango completo, use el rango completo en la nueva fórmula

Error: “Base model for the job extracted from model_name_or_path does not match model_type”

Causa: el tipo de modelo especificado en `model_type` no coincide con el modelo real del punto de control.

Solución: compruebe lo siguiente:

- El `model_type` de la fórmula coincide con el tipo de modelo original.
- La ruta del punto de control de S3 de `model_name_or_path` es correcta.
- Está utilizando la ruta del archivo `manifest.json` correcto.

Ejemplo de configuración correcta

```
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>"
```

Error: “Model configuration not found”

Causa: la ruta de S3 de `model_name_or_path` no es válida o no es accesible.

Solución:

- Compruebe que la ruta de S3 se haya copiado correctamente del archivo manifest.json.
- Asegúrese de que el rol de IAM tenga permisos para acceder al bucket de custodia.
- Confirme que el trabajo de entrenamiento anterior se completó correctamente.
- Compruebe si hay errores tipográficos en la ruta.

Regresión del rendimiento después de la iteración

Síntomas: las métricas de evaluación disminuyen después de una nueva iteración de entrenamiento.

Solución:

- Reversión: use el punto de control anterior como modelo base.
- Análisis: revise los registros de entrenamiento y la calidad de los datos para detectar la iteración fallida.
- Ajuste: modifique los hiperparámetros (reduzca el ritmo de aprendizaje), mejore la calidad de los datos o reduzca las épocas de entrenamiento.
- Reintento: inicie una nueva iteración con ajustes.

Inferencias de SageMaker

Los modelos personalizados de Amazon Nova ya están disponibles para Inferencias de SageMaker. Con Amazon Nova en SageMaker, puede empezar a obtener predicciones o inferencias a partir de sus modelos de Amazon Nova personalizados y entrenados. Sagemaker ofrece una amplia selección de opciones de implementación de modelos e infraestructuras de ML para ayudarle a satisfacer todas sus necesidades de inferencia de ML. Con Inferencias de SageMaker, puede escalar la implementación de modelos, administrar modelos de forma más eficaz en la fase de producción y reducir la carga operativa.

SageMaker le proporciona varias opciones de inferencia, como, por ejemplo, puntos de conexión en tiempo real para obtener inferencias de baja latencia y puntos de conexión asíncronos para lotes de solicitudes. Al utilizar la opción de inferencia adecuada para el caso de uso, puede garantizar una implementación e inferencia eficaces de los modelos. Para obtener más información sobre Inferencias de SageMaker, consulte [Deploy models for inference](#).

Important

Solo los modelos personalizados de rango completo y los modelos fusionados con LoRA son compatibles con Inferencias de SageMaker. En el caso de los modelos LoRA no fusionados y los modelos base, utilice Amazon Bedrock.

Características

Las siguientes características están disponibles para los modelos de Amazon Nova en Inferencias de SageMaker:

Capacidades del modelo

- Generación de texto

Implementación y escalado

- Puntos de conexión en tiempo real con selección de instancias personalizada.
- Escalado automático: ajuste automáticamente la capacidad en función de los patrones de tráfico para optimizar los costos y el uso de la GPU. Para obtener información, consulte [Automatically Scale Amazon SageMaker Models](#)
- Compatibilidad con API de transmisión para la generación de tokens en tiempo real.

Supervisión y optimización

- Integración de Amazon CloudWatch para supervisar y configurar alertas.
- Optimización de la latencia con reconocimiento de zonas de disponibilidad mediante la configuración de VPC.

Herramientas de desarrollo de

- Compatibilidad con AWS CLI: para obtener más información, consulte [AWS CLI Command Reference for SageMaker](#).
- Integración de cuadernos mediante la compatibilidad con el SDK.

Modelos e instancias compatibles

Al crear los puntos de conexión de Inferencias de SageMaker, puede definir dos variables de entorno para configurar su implementación: `CONTEXT_LENGTH` y `MAX_CONCURRENCY`.

- `CONTEXT_LENGTH`: longitud máxima total del token (entrada + salida) por solicitud
- `MAX_CONCURRENCY`: número máximo de solicitudes simultáneas que atenderá el punto de conexión

En la siguiente tabla se muestran los modelos de Amazon Nova admitidos, los tipos de instancias y las configuraciones admitidas. Los valores de `MAX_CONCURRENCY` representan la simultaneidad máxima admitida para cada configuración de `CONTEXT_LENGTH`:

Modelo	Tipo de instancia	Configuraciones admitidas	Se requiere cuantización FP8
Amazon Nova Micro	ml.g5.12xlarge	CONTEXT_LENGTH: 4.000, MAX_CONCURRENCY: 12	No
		CONTEXT_LENGTH: 8.000, MAX_CONCURRENCY: 6	
	ml.g5.24xlarge	CONTEXT_LENGTH: 8.000, MAX_CONCURRENCY: 8	No
	ml.g6e.xlarge	CONTEXT_LENGTH: 8.000, MAX_CONCURRENCY: 2	No
	ml.g6e.2xlarge	CONTEXT_LENGTH: 8.000, MAX_CONCURRENCY: 2	No
	ml.g6e.4xlarge	CONTEXT_LENGTH: 8.000, MAX_CONCURRENCY: 4	No
	ml.g6.12xlarge	CONTEXT_LENGTH: 4.000, MAX_CONCURRENCY: 12	No

Modelo	Tipo de instancia	Configuraciones admitidas	Se requiere cuantización FP8
		CONTEXT_LENGTH: 8.000, MAX_CONCURRENCY: 6	
	ml.g6.24xlarge	CONTEXT_LENGTH: 8.000, MAX_CONCURRENCY: 8	No
	ml.g6.48xlarge	CONTEXT_LENGTH: 8.000, MAX_CONCURRENCY: 12	No
	ml.p5.48xlarge	CONTEXT_LENGTH: 16.000, MAX_CONCURRENCY: 128	No
		CONTEXT_LENGTH: 64 000, MAX_CONCURRENCY: 32 CONTEXT_LENGTH: 128 000, MAX_CONCU RRENCY: 8	
Amazon Nova Lite	ml.g6.12xlarge	CONTEXT_LENGTH: 8.000, MAX_CONCURRENCY: 2	Sí - Habilidad os de forma predeterminada
	ml.g6.24xlarge	CONTEXT_LENGTH: 8.000, MAX_CONCURRENCY: 4	Sí - Habilidad os de forma predeterminada
	ml.g6.48xlarge	CONTEXT_LENGTH: 4.000, MAX_CONCURRENCY: 16	No
		CONTEXT_LENGTH: 8.000, MAX_CONCURRENCY: 8	

Modelo	Tipo de instancia	Configuraciones admitidas	Se requiere cuantización FP8
	ml.p5.48xlarge	CONTEXT_LENGTH: 16.000, MAX_CONCURRENCY: 128 CONTEXT_LENGTH: 60 000, MAX_CONCURRENCY: 8	No
Nova 2 Lite	ml.g6.48xlarge	CONTEXT_LENGTH: 8.000, MAX_CONCURRENCY: 8	Sí - Habilidad os de forma predeterminada
	ml.p5.48xlarge	CONTEXT_LENGTH: 16.000, MAX_CONCURRENCY: 128 CONTEXT_LENGTH: 64 000, MAX_CONCURRENCY: 32 CONTEXT_LENGTH: 128 000, MAX_CONCU RRENCY: 8	No

Note

La cuantización FP8 estará activada de forma predeterminada cuando sea necesaria. Los valores de MAX_CONCURRENCY que se muestran son los límites superiores de cada configuración de CONTEXT_LENGTH. Puede utilizar longitudes de contexto más bajas con la misma simultaneidad, pero si se superan estos valores, se producirá un error en la creación del punto de conexión de SageMaker.

Por ejemplo, en Amazon Nova Micro con una instancia ml.g5.12xlarge:

- CONTEXT_LENGTH=2000, MAX_CONCURRENCY=12 → válido
- CONTEXT_LENGTH=8000, MAX_CONCURRENCY=12 → rechazado (el límite de simultaneidad es 6 con una longitud de contexto de 8000)

- `CONTEXT_LENGTH=8000`, `MAX_CONCURRENCY=4` → válido
- `CONTEXT_LENGTH=8000`, `MAX_CONCURRENCY=6` → válido
- `CONTEXT_LENGTH=10000` → rechazado (la longitud máxima del contexto es 8000 en esta instancia)

Regiones de AWS compatibles

La siguiente tabla muestra las regiones de AWS en las que los modelos de Amazon Nova están disponibles para Inferencias de SageMaker:

Nombre de la región	Código de región	Disponibilidad
Este de EE. UU. (Norte de Virginia)	us-east-1	Disponible
Oeste de EE. UU. (Oregón)	us-west-2	Disponible

Imágenes de contenedor compatibles

La siguiente tabla muestra los URI de imágenes de contenedor para los modelos de Amazon Nova en Inferencias de SageMaker, organizados por región.

Región	URI de imágenes de contenedor
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

Prácticas recomendadas

Para obtener información sobre las prácticas recomendadas sobre la implementación y administración de modelos en SageMaker, consulte [Best Practices for SageMaker](#).

Soporte

Si tiene problemas o necesita asistencia con los modelos de Amazon Nova en Inferencias de SageMaker, póngase en contacto con AWS Support a través de la consola o con su administrador de cuentas de AWS.

Temas

- [Introducción](#)
- [referencia de la API](#)
- [Evaluación de los modelos alojados en Inferencias de SageMaker](#)
- [Implementación de modelos de Amazon Nova Forge en la detección de abusos de Inferencia de Amazon SageMaker](#)

Introducción

Esta guía le muestra cómo implementar modelos personalizados de Amazon Nova en puntos de conexión en tiempo real de SageMaker, configurar los parámetros de inferencia e invocar sus modelos para realizar pruebas.

Requisitos previos

Los siguientes son requisitos previos para implementar modelos de Amazon Nova en Inferencias de SageMaker:

- Cree una Cuenta de AWS: si aún no tiene una, consulte [Creating an AWS account](#).
- Permisos de IAM necesarios: asegúrese de que su usuario o rol de IAM tenga adjuntas las políticas de administración siguientes:
 - AmazonSageMakerFullAccess
 - AmazonS3FullAccess
- Versiones del SDK y de la CLI requeridas: las siguientes versiones de SDK se han probado y validado con modelos de Amazon Nova en Inferencias de SageMaker.
 - Versión 3.0.0 o superior del SDK de SageMaker para Python (`sagemaker>=3.0.0`) para un enfoque de API basado en recursos.
 - Versión 1.35.0 o superior de Boto3 (`boto3>=1.35.0`) para llamadas directas a la API. Los ejemplos de esta guía utilizan este enfoque.

- Aumento de la cuota de servicio: solicite un aumento de la cuota de servicio de Amazon SageMaker para el tipo de instancia de ML que tiene previsto utilizar para el punto de conexión de Inferencia de SageMaker (por ejemplo, `m1.p5.48xlarge` for endpoint usage). Para ver una lista de los tipos de instancia admitidos, consulte [the section called “Modelos e instancias compatibles”](#). Para solicitar un aumento, consulte [Solicitud de aumento de cuota](#). Para obtener más información sobre las cuotas de instancias de SageMaker, consulte [Puntos de conexión y cuotas de Amazon SageMaker](#).

Paso 1: configure las credenciales de AWS

Configure las credenciales de AWS con uno de los siguientes métodos:

Opción 1: AWS CLI (recomendado)

```
aws configure
```

Ingresa la clave de acceso de AWS, la clave secreta y el nombre de la región predeterminada cuando se le solicite.

Opción 2: archivo de credenciales AWS

Cree o edite `~/.aws/credentials`:

```
[default]
aws_access_key_id = YOUR_ACCESS_KEY
aws_secret_access_key = YOUR_SECRET_KEY
```

Opción 3: variables de entorno

```
export AWS_ACCESS_KEY_ID=your_access_key
export AWS_SECRET_ACCESS_KEY=your_secret_key
```

Note

Para obtener más información sobre las credenciales de AWS, consulte [Opciones de los archivos de configuración y credenciales en la AWS CLI](#).

Inicialización de clientes de AWS

Cree un script o cuaderno de Python con el siguiente código para inicializar el SDK de AWS y verificar sus credenciales:

```
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.")
```

Si la autenticación se realiza correctamente, debería ver una salida que confirma el ID de su cuenta de AWS.

Paso 2: cree un rol de puesta en marcha de SageMaker AI

Un rol de puesta en marcha de SageMaker es un rol de IAM que concede permisos a SageMaker para acceder a los recursos de AWS en su nombre, como los buckets de Amazon S3 para artefactos de modelos y CloudWatch para el registro.

Creación del rol de puesta en marcha

 Note

La creación de roles de IAM requiere los permisos `iam:CreateRole` y `iam:AttachRolePolicy`. Asegúrese de que el usuario o el rol de IAM tenga estos permisos antes de continuar.

El código siguiente crea un rol de IAM con los permisos necesarios para implementar modelos personalizados de 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 un rol de puesta en marcha existente (opcional)

Si ya tiene un rol de puesta en marcha de SageMaker, puede usarlo en su lugar:

```
# Replace with your existing role ARN  
SAGEMAKER_EXECUTION_ROLE_ARN = "arn:aws:iam::YOUR_ACCOUNT_ID:role/  
YOUR_EXISTING_ROLE_NAME"
```

Para buscar los roles de SageMaker existentes en su cuenta:

```
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

El rol de puesta en marcha debe tener una relación de confianza con `sagemaker.amazonaws.com` y permisos para acceder a los recursos de Amazon S3 y SageMaker.

Para obtener más información sobre los roles de puesta en marcha de SageMaker, consulte [SageMaker Roles](#).

Paso 3: configure los parámetros del modelo

Configure los parámetros de implementación de su modelo de Amazon Nova. Estos ajustes controlan el comportamiento del modelo, la asignación de recursos y las características de inferencia. Para obtener una lista de los tipos de instancias compatibles y los valores de `CONTEXT_LENGTH` y `MAX_CONCURRENCY` admitidos para cada uno, consulte [the section called “Modelos e instancias compatibles”](#).

Parámetros requeridos

- **IMAGE:** el URI de imagen del contenedor de Docker para el contenedor de inferencias de Amazon Nova. Lo proporcionará AWS.
- **CONTEXT_LENGTH:** longitud del contexto del modelo.
- **MAX_CONCURRENCY:** número máximo de secuencias por iteración; establece el límite de cuántas solicitudes de usuarios individuales (peticiones) se pueden procesar simultáneamente en un solo lote en la GPU. Rango: valor entero mayor que 0.

Parámetros de generación opcionales

- **DEFAULT_TEMPERATURE:** controla la asignación al azar en la generación. Rango: de 0,0 a 2,0 (0.0 = determinista, más alto = asignación al azar mayor).
- **DEFAULT_TOP_P:** umbral de muestreo del núcleo para la selección de tokens. Rango: del 1e-10 al 1,0.
- **DEFAULT_TOP_K:** limita la selección de tokens a los K más probables. Rango: número entero -1 o mayor (-1 = sin límite).
- **DEFAULT_MAX_NEW_TOKENS:** número máximo de tokens que se generarán en respuesta (es decir, número máximo de tokens de salida). Rango: número entero 1 o mayor.
- **DEFAULT_LOGPROBS:** número de probabilidades logarítmicas que se devolverán por token. Rango: número entero del 1 al 20.

Configurar su implementación

```
# 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}")

```

Configuración de los parámetros específicos de la implementación

Ahora configure los parámetros específicos de la implementación de su modelo de Amazon Nova, como la ubicación de los artefactos del modelo y la selección del tipo de instancia.

Definición del identificador de la implementación

```

# Deployment identifier - use a descriptive name for your use case
JOB_NAME = "my-nova-deployment"

```

Definición de la ubicación de los artefactos del modelo

Proporcione el URI de Amazon S3 en el que se almacenan los artefactos de los modelos entrenados de Amazon Nova. Esta debe ser la ubicación de salida de su trabajo de entrenamiento o refinamiento del modelo.

```
# 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/"
```

Selección de la variante del modelo y del tipo de instancia

```
# 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}")
```

Convenciones de nomenclatura

El código genera automáticamente nombres consistentes para los recursos de AWS:

- Nombre del modelo: {JOB_NAME}-{model}-{instance-type}
- Configuración del punto de conexión: {MODEL_NAME}-Config
- Nombre del punto de conexión: {MODEL_NAME}-Endpoint

Paso 4: cree la configuración del modelo y del punto de conexión de SageMaker

En este paso, creará dos recursos esenciales: un objeto de modelo de SageMaker que haga referencia a los artefactos del modelo de Amazon Nova y una configuración de punto de conexión que defina cómo se implementará el modelo.

Modelo de SageMaker: objeto de modelo que empaqueta la imagen del contenedor de inferencia, la ubicación de los artefactos del modelo y la configuración del entorno. Se trata de un recurso reutilizable que se puede implementar en varios puntos de conexión.

Configuración de punto de conexión: define la configuración de la infraestructura de la implementación, como el tipo de instancia, el número de instancias y las variantes del modelo. Esto le permite administrar la configuración de implementación de forma independiente del propio modelo.

Cree el modelo de SageMaker

El siguiente código crea un modelo de SageMaker que hace referencia a los artefactos del modelo de 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}")
```

Parámetros clave:

- **ModelName**: identificador único para su modelo
- **Image**: URI de imagen del contenedor de Docker para las inferencias de Amazon Nova
- **ModelDataSource**: ubicación en Amazon S3 de los artefactos de su modelo
- **Environment**: variables de entorno configuradas en el paso 3
- **ExecutionRoleArn**: rol de IAM del paso 2
- **EnableNetworkIsolation**: establezca el valor en True para mejorar la seguridad (evita que el contenedor haga llamadas salientes a la red)

Creación de la configuración de punto de conexión

A continuación, cree una configuración de punto de conexión que defina la infraestructura de la implementación:

```
# 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}")
```

Parámetros clave:

- **VariantName**: identificador de esta variante del modelo (utilice “principal” para las implementaciones de un solo modelo)
- **ModelName**: hace referencia al modelo creado anteriormente

- **InitialInstanceCount**: número de instancias que se van a implementar (comience con 1 y escale más adelante si es necesario)
- **InstanceType**: tipo de instancia de ML seleccionado en el paso 3

Verificación de la creación de recursos

Puede verificar que los recursos se crearon correctamente:

```
# 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")
```

Paso 5: implemente el punto de conexión

El siguiente paso consiste en implementar su modelo de Amazon Nova mediante la creación de un punto de conexión en tiempo real de SageMaker. Este punto de conexión alojará su modelo y proporcionará un punto de conexión HTTPS seguro para realizar solicitudes de inferencia.

La creación del punto de conexión suele tardar entre 15 y 30 minutos, ya que AWS aprovisiona la infraestructura, descarga los artefactos del modelo e inicializa el contenedor de inferencias.

Cree el punto de conexión

```
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}")
```

Supervisión de la creación de puntos de conexión

El siguiente código sondea el estado del punto de conexión hasta que se complete la implementación:

```
# 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
```

Comprobación de que el punto de conexión esté listo

Cuando el punto de conexión esté en funcionamiento, puede verificar su configuración:

```
# 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

```

Solución de problemas de creación de puntos de conexión

Motivos de error comunes:

- Capacidad insuficiente: el tipo de instancia solicitado no está disponible en su región.
 - Solución: pruebe un tipo de instancia diferente o solicite un aumento de cuota
- Permisos de IAM: el rol de puesta en marcha carece de los permisos necesarios.
 - Solución: compruebe que el rol tenga acceso a los artefactos del modelo de Amazon S3 y a los permisos de SageMaker necesarios
- No se encontraron los artefactos del modelo: el URI de Amazon S3 es incorrecto o no se puede acceder a él.
 - Solución: compruebe el URI de Amazon S3 y los permisos del bucket, y asegúrese de que se encuentra en la región correcta.
- Límites de recursos: se han superado los límites de las cuentas para los puntos de conexión o las instancias.
 - Solución: solicite un aumento de la cuota de servicio a través de Service Quotas o AWS Support.

 Note

Si tiene que eliminar un punto de conexión defectuoso y empezar de nuevo, haga lo siguiente:

```
sagemaker.delete_endpoint(EndpointName=ENDPOINT_NAME)
```

Paso 6: invoque el punto de conexión

Cuando el punto de conexión esté en funcionamiento, puede enviar solicitudes de inferencia para generar predicciones a partir de su modelo de Amazon Nova. SageMaker admite puntos de conexión síncronos (en tiempo real con modos de transmisión o sin transmisión) y puntos de conexión asíncronos (basados en Amazon S3 para el procesamiento por lotes).

Configuración del cliente de tiempo de ejecución

Cree un cliente de tiempo de ejecución de SageMaker con la configuración de tiempo de espera adecuada:

```
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)
```

Creación de una función de inferencia universal

La siguiente función gestiona las solicitudes de transmisión y de no transmisión:

```
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)}")
```

Ejemplo 1: finalización de un chat sin transmisión

Use el formato de chat para las interacciones conversacionales:

```
# 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)
```

Respuesta de ejemplo:

```
{
    "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
}
}

```

Ejemplo 2: finalización de texto simple

Use el formato de finalización para generar texto simple:

```

# 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)

```

Respuesta de ejemplo:

```

{
  "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
  }
}

```

Ejemplo 3: finalización de un chat con transmisión

```

# 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)

```

Ejemplo de salida de transmisión:

```

Chunk: data: {"id":"chatcmpl-029ca032-fa01-4868-80b7-
c4cb1af90fb9","object":"chat.completion.chunk","created":1772060532,"model":"default","choices"
[{"index":0,"delta":
{"role":"assistant","content":"","reasoning_content":null},"logprobs":null,"finish_reason":null
Chunk: data: {"id":"chatcmpl-029ca032-fa01-4868-80b7-
c4cb1af90fb9","object":"chat.completion.chunk","created":1772060532,"model":"default","choices"
[{"index":0,"delta":{"content":" Once","reasoning_content":null},"logprobs":
{"content":[{"token":"\u2581Once","logprob":-0.6078429222106934,"bytes":
[226,150,129,79,110,99,101],"top_logprobs":
[{"token":"\u2581Once","logprob":-0.6078429222106934,"bytes":
[226,150,129,79,110,99,101]}],"token":"\u2581In","logprob":-0.7864127159118652,"bytes":
[226,150,129,73,110]}]}]}],"finish_reason":null,"token_ids":null}}]
Chunk: data: {"id":"chatcmpl-029ca032-fa01-4868-80b7-
c4cb1af90fb9","object":"chat.completion.chunk","created":1772060532,"model":"default","choices"
[{"index":0,"delta":{"content":" upon","reasoning_content":null},"logprobs":
{"content":[{"token":"\u2581upon","logprob":-0.0012345,"bytes":
[226,150,129,117,112,111,110],"top_logprobs":
[{"token":"\u2581upon","logprob":-0.0012345,"bytes":[226,150,129,117,112,111,110]}],
{"token":"\u2581a","logprob":-6.789,"bytes":
[226,150,129,97]}]}]}],"finish_reason":null,"token_ids":null}}]
Chunk: data: {"id":"chatcmpl-029ca032-fa01-4868-80b7-
c4cb1af90fb9","object":"chat.completion.chunk","created":1772060532,"model":"default","choices"
[{"index":0,"delta":{"content":" a","reasoning_content":null},"logprobs":
{"content":[{"token":"\u2581a","logprob":-0.0001234,"bytes":
[226,150,129,97],"top_logprobs":[{"token":"\u2581a","logprob":-0.0001234,"bytes":
[226,150,129,97]}],"token":"\u2581time","logprob":-9.123,"bytes":
[226,150,129,116,105,109,101]}]}]}],"finish_reason":null,"token_ids":null}}]
Chunk: data: {"id":"chatcmpl-029ca032-fa01-4868-80b7-
c4cb1af90fb9","object":"chat.completion.chunk","created":1772060532,"model":"default","choices"
[{"index":0,"delta":{"content":" time","reasoning_content":null},"logprobs":

```

```

{"content":[{"token":"\u2581time","logprob":-0.0023456,"bytes":
[226,150,129,116,105,109,101],"top_logprobs":
[{"token":"\u2581time","logprob":-0.0023456,"bytes":[226,150,129,116,105,109,101]},
{"token":"","","logprob":-6.012,"bytes":
[44]}]}]},"finish_reason":null,"token_ids":null]]}

# Additional chunks...

Chunk: data: {"id":"chatcmpl-029ca032-fa01-4868-80b7-
c4cb1af90fb9","object":"chat.completion.chunk","created":1772060532,"model":"default","choices":
[{"index":0,"delta":{"logprobs":null,"finish_reason":"stop"}],"usage":
{"prompt_tokens":15,"completion_tokens":87,"total_tokens":102}}
Chunk: data: [DONE]

```

Ejemplo 4: finalización de un chat multimodal

Use el formato multimodal para la entrada de imágenes y 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)

```

Respuesta de ejemplo:

```

{
    "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
}
```

Paso 7 (opcional): elimine recursos

Para evitar incurrir en gastos innecesarios, elimine los recursos de AWS que creó durante este tutorial. Los puntos de conexión de SageMaker incurren en cargos mientras están en funcionamiento, incluso si no realiza activamente solicitudes de inferencia.

Important

La eliminación de los recursos es permanente y no se puede deshacer. Asegúrese de que ya no necesite estos recursos antes de continuar.

Eliminación del punto de conexión

```
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

La eliminación de puntos de conexión es asíncrona. Puede supervisar el estado de la eliminación:

```
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
```

Eliminación de la configuración de punto de conexión

Una vez eliminado el punto de conexión, elimine su configuración.

```
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}")
```

Eliminación del modelo

Elimine el objeto de modelo de 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}")
```

referencia de la API

Los modelos de Amazon Nova en SageMaker utilizan la API estándar de Tiempo de ejecución de SageMaker Runtime para realizar inferencias. Para obtener la documentación completa de la API, consulte [Test a deployed model](#).

Invocación del punto de conexión

Los modelos de Amazon Nova en SageMaker admiten dos métodos de invocación:

- Invocación sincrónica: utilice la API [InvokeEndpoint](#) para solicitudes de inferencia en tiempo real sin transmisión.
- Invocación con transmisión: utilice la API [InvokeEndpointWithResponseStream](#) para las solicitudes de inferencia en tiempo real con transmisión.

Formato de solicitudes

Los modelos de Amazon Nova admiten dos formatos de solicitud:

Formato de finalización de chat

Use este formato para las interacciones conversacionales:

```
{
  "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 finalización de texto

Use este formato para generar texto simple:

```
{  
  "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 finalización de chat multimodal

Use este formato para la entrada de imágenes y 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  
}
```

Parámetros de solicitud

- **messages (matriz):** para el formato de finalización de chat. Matriz de objetos de mensaje con los campos `role` y `content`. El contenido puede ser una cadena de solo texto o una matriz de entradas multimodales.
- **prompt (cadena):** para el formato de finalización de texto. El texto de entrada desde el que se generará.
- **max_tokens (entero):** número máximo de tokens que se generarán en la respuesta. Rango: 1 o más.
- **max_completion_tokens (entero):** alternativa a `max_tokens` para el formato de finalización de chat. Número máximo de tokens de finalización que se generarán.
- **temperature (float):** controla la asignación al azar en la generación. Rango: de 0,0 a 2,0 (0,0 = determinista, 2,0 = asignación al azar máxima).
- **top_p (float):** umbral de muestreo del núcleo Rango: del 1e-10 al 1,0.
- **top_k (entero):** limita la selección de tokens a los K más probables. Rango: entero -1 o mayor (-1 = sin límite).
- **stream (booleano):** indica si se debe transmitir la respuesta. Establezca el valor en `true` para transmitir o en `false` si no quiere transmisión.
- **logprobs (booleano/entero):** para finalizaciones de chat, use un valor booleano. Para la finalización de texto, utilice un número entero como número de probabilidades logarítmicas que se deben devolver. Rango: del 1 al 20
- **top_logprobs (entero):** número de tokens más probables para los cuales devolver probabilidades logarítmicas (solo para finalizaciones de chat).
- **reasoning_effort (cadena):** nivel de esfuerzo de razonamiento. Opciones: “bajo”, “alto” (finalizaciones de chat solo para los modelos personalizados de Nova 2 Lite).
- **allowed_token_ids (matriz):** lista de ID de token que se pueden generar. Restringe la salida a los tokens especificados.
- **truncate_prompt_tokens (entero):** trunca la petición a este número de símbolos si supera el límite.

- `stream_options` (objeto): opciones para transmitir las respuestas. Contiene el valor booleano de `include_usage` que indica si incluir el uso de tokens en las respuestas transmitidas.

Formato de respuesta

El formato de respuesta depende del método de invocación y del tipo de solicitud:

Respuesta de finalización de chat (sin transmisión)

Para solicitudes de finalización de chat sincrónicas:

```
{
  "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]
}

```

Respuesta de finalización de texto (sin transmisión)

Para solicitudes de finalización de texto sincrónicas:

```

{
  "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
  }
}
}
}

```

Respuesta de finalización de chat con transmisión

En el caso de las solicitudes de finalización de chat con transmisión, las respuestas se envían como eventos enviados por el 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
}
],
"usage": null,
"prompt_token_ids": null
}

data: {
    "id": "chatcmpl-123e4567-e89b-12d3-a456-426614174000",
    "object": "chat.completion.chunk",
    "created": 1677652288,
    "model": "nova-micro-custom",
    "choices": [
        {
            "index": 0,
            "delta": {
                "content": "! I'm"
            },
            "logprobs": null,
            "finish_reason": null,
            "stop_reason": null
        }
    ],
    "usage": null
}

data: {
    "id": "chatcmpl-123e4567-e89b-12d3-a456-426614174000",
    "object": "chat.completion.chunk",

```



```

"created": 1677652288,
"model": "nova-micro-custom",
"choices": [
  {
    "index": 0,
    "delta": {},
    "finish_reason": "stop",
    "stop_reason": null
  }
],
"usage": {
  "prompt_tokens": 9,
  "completion_tokens": 12,
  "total_tokens": 21,
  "prompt_tokens_details": {
    "cached_tokens": 0
  }
}
}
data: [DONE]

```

Respuesta de finalización de texto con transmisión

Para solicitudes de finalización de texto con transmisión:

```

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]
```

Explicación de los campos de respuesta

- `id`: identificador único de la finalización
- `object`: tipo de objeto devuelto (“chat.completion”, “text_completion”, “chat.completion.chunk”)
- `created`: marca de tiempo Unix del momento en que se creó la finalización
- `model`: modelo utilizado para la finalización
- `choices`: matriz de opciones de finalización
- `usage`: información sobre el uso de las tokens, lo que incluye la petición, la finalización y el número total de tokens
- `logprobs`: información de probabilidades logarítmicas de los tokens (cuando se solicite)
- `finish_reason`: motivo por el que el modelo dejó de generar (“stop”, “length”, “content_filter”)
- `delta`: contenido incremental en las respuestas con transmisión
- `reasoning`: contenido de razonamiento cuando se use `reasoning_effort`
- `token_ids`: matriz de ID de tokens para el texto generado

Para obtener la documentación completa de la API, consulte [InvokeEndpoint API reference](#) y [InvokeEndpointWithResponseStream API reference](#).

Evaluación de los modelos alojados en Inferencias de SageMaker

Esta guía explica cómo evaluar los modelos personalizados de Amazon Nova implementados en los puntos de conexión de Inferencias de SageMaker mediante [Inspect AI](#), un marco de evaluación de código abierto.

Note

Para ver un tutorial práctico, consulte [SageMaker Inspect AI quickstart notebook](#).

Descripción general

Puede evaluar los modelos personalizados de Amazon Nova implementados en los puntos de conexión de SageMaker utilizando pruebas comparativas estandarizadas de la comunidad de investigadores de IA. Este enfoque le permite lo siguiente:

- Evaluar modelos personalizados de Amazon Nova (refinados, destilados o adaptados de alguna manera) a escala
- Poner en marcha evaluaciones con inferencia paralela en varias instancias del punto de conexión
- Comparar el rendimiento del modelo mediante pruebas comparativas como MMLU, TruthfulQA y HumanEval
- Integrar con su infraestructura de SageMaker existente

Modelos compatibles

El proveedor de Inferencias de SageMaker funciona con:

- Modelos de Amazon Nova (Nova Micro, Nova Lite, Nova Lite 2)
- Modelos implementados mediante servidores de inferencia compatibles con vLLM u OpenAI
- Cualquier punto de conexión compatible con el formato de la API de finalizaciones de chat de OpenAI

Requisitos previos

Antes de comenzar, asegúrese de que dispone de lo siguiente:

- Una Cuenta de AWS con permisos para crear e invocar puntos de conexión de SageMaker
- Credenciales de AWS configuradas mediante AWS CLI, variables de entorno o roles de IAM
- Python 3.9 o superior

Permisos de IAM necesarios

El usuario o rol de IAM necesita los siguientes permisos:

```
{  
  "Version": "2012-10-17",  
  "Statement": [  

```

```
{
  "Effect": "Allow",
  "Action": [
    "sagemaker:InvokeEndpoint",
    "sagemaker:DescribeEndpoint"
  ],
  "Resource": "arn:aws:sagemaker:*:*:endpoint/*"
}
```

Paso 1: implemente un punto de conexión de SageMaker

Antes de poner en marcha las evaluaciones, necesita un punto de conexión de Inferencias de SageMaker que use el modelo.

Para obtener instrucciones sobre cómo crear un punto de conexión de Inferencias de SageMaker con modelos de Amazon Nova, consulte [the section called “Introducción”](#).

Cuando el punto de conexión esté en estado InService, anote el nombre del punto de conexión para usarlo en los comandos de evaluación.

Paso 2: instale las dependencias de evaluación

Cree un entorno virtual de Python e instale los paquetes necesarios.

```
# 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
```

Paso 3: configure las credenciales de AWS

Elija uno de los siguientes métodos de autenticación:

Opción 1: AWS CLI (recomendado)

```
aws configure
```

Ingresa el ID de su clave de acceso de AWS, la clave de acceso secreta y el nombre de la región predeterminada cuando se le solicite.

Opción 2: variables de entorno

```
export AWS_ACCESS_KEY_ID=your_access_key
export AWS_SECRET_ACCESS_KEY=your_secret_key
export AWS_DEFAULT_REGION=us-west-2
```

Opción 3: rol de IAM

Si se usan Amazon EC2 o cuadernos de SageMaker, el rol de IAM de la instancia se utiliza automáticamente.

Verificación de credenciales

```
import boto3

sts = boto3.client('sts')
identity = sts.get_caller_identity()
print(f"Account: {identity['Account']}")
print(f>User/Role: {identity['Arn']}")
```

Paso 4: instalación del proveedor de SageMaker

El proveedor de SageMaker permite que Inspect AI se comuniquen con sus puntos de conexión de SageMaker. El proceso de instalación del proveedor aparece simplificado en el [cuaderno de inicio rápido](#).

Paso 5: descargue las pruebas comparativas de evaluación

Clone el repositorio Inspect Evals para acceder a las pruebas comparativas estándar:

```
git clone https://github.com/UKGovernmentBEIS/inspect_evals.git
```

Este repositorio incluye pruebas comparativas como:

- MMLU y MMLU-Pro (conocimiento y razonamiento)
- TruthfulQA (veracidad)
- HumanEval (generación de código)
- GSM8K (razonamiento matemático)

Paso 6: realice evaluaciones

Lleve a cabo una evaluación con su punto de conexión de 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
```

Parámetros clave

Parámetro	Predeterminado	Descripción
--max-connections	10	Número de solicitudes paralelas al punto de conexión. Escale con el número de instancias (por ejemplo, 10 instancias × 25 = 250).
--max-retries	3	Reintentos en caso de error. Utilice 50-100 para evaluaciones de gran tamaño.
-M region_name	us-east-1	Región de AWS en la que se implementa el punto de conexión.
-M read_timeout	600	Tiempo de espera de la solicitud en segundos.
-M connect_timeout	60	Tiempo de espera de la conexión en segundos.

Recomendaciones de refinamiento

Para un punto de conexión de varias instancias:

```
# 10-instance endpoint example
--max-connections 250    # ~25 connections per instance
--max-retries 100        # Handle transient errors
```

Si se establece un valor demasiado alto para `--max-connections`, es posible que el punto de conexión se sobrecargue y se produzcan limitaciones. Si se establece un valor demasiado bajo, se infrutiliza la capacidad.

Paso 7: visualización de los resultados

Inicie el lector de Inspect AI para analizar los resultados de la evaluación:

```
inspect view
```

El lector muestra lo siguiente:

- Puntuaciones y métricas generales
- Resultados por muestra con las respuestas del modelo
- Análisis de errores y patrones de error

Administración de puntos de conexión

Actualizar un punto de conexión

Para actualizar un punto de conexión existente con un nuevo modelo o configuración:

```
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
)
```

Eliminación de un punto de conexión


```
sagemaker.delete_endpoint(EndpointName=ENDPOINT_NAME)
```

Incorporación de pruebas comparativas personalizadas

Puede agregar nuevas pruebas comparativas a Inspect AI mediante el siguiente flujo de trabajo:

1. Estudie el formato del conjunto de datos de la prueba comparativa y las métricas de evaluación.
2. Revise implementaciones similares en `inspect_evals/`.
3. Cree un archivo de tareas que convierta los registros del conjunto de datos en muestras de Inspect AI.
4. Implemente los solucionadores y evaluadores adecuados.
5. Valide con una pequeña prueba.

Estructura de tarea de ejemplo:

```
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()
    )
```

Solución de problemas

Problemas comunes

Limitación o tiempos de espera del punto de conexión

- Reduzca `--max-connections`
- Aumente `--max-retries`
- Compruebe las métricas de CloudWatch de los puntos de conexión para ver si hay problemas de capacidad

Errores de autenticación

- Compruebe que las credenciales de AWS estén configuradas correctamente:
- Compruebe que los permisos de IAM incluyan `sagemaker:InvokeEndpoint`

Errores del modelo

- Compruebe que el punto de conexión esté en estado `InService`
- Compruebe que el modelo sea compatible con el formato de la API de finalizaciones de chat de OpenAI

Recursos relacionados

- [Documentación de Inspect AI](#)
- [Repositorio Inspect Evals](#)
- [SageMaker Developer Guide](#)
- [Deploy Models for Inference](#)
- [Configuración de la AWS CLI](#)

Implementación de modelos de Amazon Nova Forge en la detección de abusos de Inferencia de Amazon SageMaker

AWS tiene el compromiso de usar responsablemente la IA. Para ayudar a prevenir un posible uso indebido, al implementar modelos de Amazon Nova Forge en Inferencia de Amazon SageMaker, Inferencia de SageMaker implementa mecanismos automatizados de detección de abusos para identificar las posibles infracciones de la [Política de uso aceptable](#) (AUP) y las Condiciones del servicio de AWS, lo que incluye la [Política de IA responsable](#).

Nuestros mecanismos de detección de abusos están totalmente automatizados, por lo que no se puede revisar ni acceder a las entradas de usuario ni a las salidas del modelo.

La detección automática de abusos incluye:

- Categorización de contenido: utilizamos clasificadores para detectar contenido dañino (como el que incita a la violencia) en las entradas del usuario y en las salidas del modelo. Un clasificador es un algoritmo que procesa las entradas y salidas del modelo y asigna el tipo de daño y el nivel de

confianza. Podemos utilizar estos clasificadores en el uso del modelo de Amazon Nova Forge. El proceso de clasificación está automatizado y no implica la revisión humana de entradas de usuario ni de salidas del modelo.

- **Identificación de patrones:** utilizamos métricas de clasificadores para identificar posibles infracciones y comportamientos recurrentes. Podemos recopilar y compartir métricas de clasificadores anónimas. Inferencia de Amazon SageMaker no almacena las entradas del usuario ni las salidas del modelo.
- **Detección y bloqueo de material de abuso sexual infantil:** usted es responsable del contenido que usted y sus usuarios finales suban a Inferencia de Amazon SageMaker y debe asegurarse de que no contenga imágenes ilegales. Para ayudar a detener la difusión de material de abuso sexual infantil, al implementar un modelo de Amazon Nova Forge en Inferencia de Amazon SageMaker, Inferencia de SageMaker puede utilizar mecanismos automatizados de detección de abusos (como la tecnología de coincidencia de hash o los clasificadores) para detectar posible material de abuso sexual infantil. Si Inferencia de Amazon SageMaker detecta posible material de abuso sexual infantil en las entradas de imágenes, bloqueará la solicitud y usted recibirá un mensaje de error automático. Inferencia de Amazon SageMaker también puede remitir una denuncia al Centro Nacional para Menores Desaparecidos y Explotados (NCMEC, por sus siglas en inglés) o a la autoridad pertinente. Nos tomamos muy en serio el CSAM y, por ello, no dejaremos de actualizar nuestros mecanismos de detección, bloqueo y notificación. Es posible que las leyes aplicables le exijan que tome medidas adicionales. Usted es responsable de tomar dichas medidas.

Cuando nuestros mecanismos automatizados de detección de abusos identifiquen posibles infracciones, podemos solicitar información sobre el uso que hace de Inferencia de Amazon SageMaker y sobre el cumplimiento de nuestras condiciones del servicio. En el caso de que no responda, se niegue o no pueda cumplir con estos términos o políticas, AWS podría suspender su acceso a Inferencia de Amazon SageMaker. También es posible que se le facturen los trabajos de inferencia que hayan fallado si nuestras pruebas automatizadas detectan que las respuestas de los modelos no cumplen con nuestros términos y políticas.

Si tiene alguna pregunta, póngase en contacto con AWS Support. Para obtener más información, consulte [Preguntas frecuentes sobre Amazon SageMaker](#).

Inferencia de Amazon Bedrock

Cuando haya entrenado y probado el modelo de Amazon Nova, puede implementarlo en Amazon Bedrock para llevar a cabo inferencias a escala de producción. El proceso de implementación

implica la creación de un modelo de Amazon Bedrock con la API `CreateCustomModel`, la exportación de los artefactos del modelo a dicho modelo desde un bucket de Amazon S3 administrado y, a continuación, una vez que el modelo esté ACTIVO, la configuración de un punto de conexión con inferencia de rendimiento bajo demanda o aprovisionada.

Después de crear un modelo personalizado en SageMaker, puede utilizar la API `CreateCustomModel` para implementarlo en Amazon Bedrock desde la custodia de SageMaker para ejecutar inferencias. A continuación, puede utilizar `CreateCustomModelDeployment` para crear un punto de conexión de inferencia bajo demanda o configurar la inferencia de rendimiento aprovisionada para un modelo de refinamiento eficiente de parámetros (PEFT). Puede configurar la inferencia de rendimiento aprovisionada para un modelo personalizado de rango completo.

También puede usar el SDK de Amazon Nova Forge para implementar modelos personalizados de Amazon Nova. El SDK de Amazon Nova Forge proporciona una experiencia optimizada para extraer la información relevante de un trabajo de entrenamiento o de un punto de control del modelo de S3 y publicarla en Amazon Bedrock. Para obtener información, consulte [SDK de Amazon Nova Forge](#).

Para ver los pasos detallados a fin de configurar la inferencia de Amazon Bedrock para un modelo personalizado, consulte [Implementación de modelos personalizados de Amazon Nova en Amazon Bedrock](#).

En la siguiente sección se ofrecen más detalles sobre la inferencia bajo demanda en modelos personalizados.

Implementar un modelo personalizado para inferencia bajo demanda

Una vez que haya creado correctamente un modelo personalizado con un trabajo de personalización del modelo (afinación, síntesis o entrenamiento previo continuo), podrá configurar la inferencia bajo demanda para el modelo.

Para configurar la inferencia bajo demanda para un modelo personalizado, debe implementarlo con una implementación de modelo personalizado. Tras implementar el modelo personalizado, utiliza el nombre de recurso de Amazon (ARN) de la implementación como el parámetro de `modelId` en sus operaciones de `InvokeModel` o en las de la API de `Converse`. Puede usar el modelo implementado para realizar inferencias bajo demanda con características de Amazon Bedrock, como áreas de juego, agentes y bases de conocimiento.

Temas

- [Modelos compatibles](#)

- [Implementar un modelo personalizado](#)
- [Utilice una implementación para realizar inferencias bajo demanda](#)
- [Eliminar una implementación de un modelo](#)

Modelos compatibles

Puede configurar la inferencia bajo demanda para los siguientes modelos:

- Amazon Nova Canvas
- Amazon Nova Lite
- Amazon Nova Micro
- Amazon Nova Pro

Implementar un modelo personalizado

Puede implementar un modelo personalizado con la consola de Amazon Bedrock, la AWS Command Line Interface o SDK de AWS. Para obtener información sobre el uso de la implementación para la inferencia, consulte [Usar una implementación para la inferencia bajo demanda](#).

Temas

- [Implementación de un modelo personalizado \(consola\)](#)
- [Implementar un modelo personalizado \(AWS Command Line Interface\)](#)
- [Implemente un modelo personalizado \(SDK de AWS\)](#)

Implementación de un modelo personalizado (consola)

Puede implementar un modelo personalizado en la página Modelos personalizados de la siguiente manera. También puede implementar un modelo en la página Modelos personalizados bajo demanda con los mismos campos. Para encontrar esta página, en Inferencia y evaluación, en el panel de navegación, seleccione Modelo personalizado bajo demanda.

Para implementar un modelo

1. Inicie sesión en la Consola de administración de AWS con un [rol de IAM con los permisos de Amazon Bedrock](#) y abra la consola de Amazon Bedrock en <https://console.aws.amazon.com/nova/>.

2. En el panel de navegación de la izquierda, seleccione Modelos personalizados en Modelos fundacionales.
3. En la pestaña Modelos, elija el botón de opción correspondiente al modelo que desea implementar.
4. Elija Configurar inferencia y seleccione Implementar bajo demanda.
5. En Detalles de la implementación, indique la siguiente información.
 - Nombre de la implementación (obligatorio): introduzca un nombre único para la implementación.
 - Descripción (opcional): ingrese una descripción para la implementación.
 - Etiquetas (opcional): agregue etiquetas para la asignación de costos y la administración de recursos.
6. Seleccione Crear. Cuando se muestre el estado Completed, el modelo personalizado estará listo para la inferencia bajo demanda. Para obtener más información sobre el uso del modelo personalizado, consulte [Usar una implementación para una inferencia bajo demanda](#).

Implementar un modelo personalizado (AWS Command Line Interface)

Para implementar un modelo personalizado para la inferencia bajo demanda mediante la AWS Command Line Interface, utilice el comando `create-custom-model-deployment` con el nombre de recurso de Amazon (ARN) del modelo personalizado. Este comando usa la operación de la API de [CreateCustomModelDeployment](#). Devuelve el ARN de la implementación que puede usar como el `modelId` al realizar solicitudes de inferencia. Para obtener información sobre el uso de la implementación para la inferencia, consulte [Usar una implementación para la inferencia bajo demanda](#).

```
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

```

Implemente un modelo personalizado (SDK de AWS)

Para implementar un modelo personalizado para la inferencia bajo demanda, utilice la operación de API de [CreateCustomModelDeployment](#) con el nombre de recurso de Amazon (ARN) del modelo personalizado. La respuesta devuelve el ARN de la implementación que puede usar como el `modelId` al realizar solicitudes de inferencia. Para obtener información sobre el uso de la implementación para la inferencia, consulte [Usar una implementación para la inferencia bajo demanda](#).

El código siguiente muestra cómo utilizar el SDK para Python (Boto3) para implementar un 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
```

Utilice una implementación para realizar inferencias bajo demanda

Después de implementar su modelo personalizado para la inferencia bajo demanda, puede usarlo para generar respuestas mediante solicitudes de inferencia. Para operaciones de `InvokeModel` o de `Converse`, utilice la implementación del nombre de recurso de Amazon (ARN) como el `modelId`.

Para obtener información sobre cómo realizar solicitudes de inferencia, consulte los siguientes temas:

- [Envío de solicitudes y generación de respuestas con inferencia de modelos](#)
- [Requisitos previos para ejecutar la inferencia de modelos](#)
- [Envío de solicitudes y generación de respuestas mediante la API](#)

Eliminar una implementación de un modelo

Una vez que haya terminado de usar su modelo para la inferencia bajo demanda, puede eliminar la implementación. Después de eliminar la implementación, no podrá usarla para la inferencia bajo demanda, pero esta acción no eliminará el modelo personalizado subyacente.

Puede eliminar una implementación de modelo personalizada con la consola de Amazon Bedrock, la AWS Command Line Interface o los SDK de AWS.

Important

La eliminación de una implementación de modelo personalizado es irreversible. Asegúrese de que ya no necesita la implementación antes de proceder a la eliminación. Si necesita

volver a utilizar el modelo personalizado para la inferencia bajo demanda, debe crear una nueva implementación.

Temas

- [Eliminar una implementación de modelo personalizado \(consola\)](#)
- [Eliminación de la implementación de un modelo \(AWS Command Line Interface\)](#)
- [Eliminar una implementación de modelo personalizado \(SDK de AWS\)](#)

Eliminar una implementación de modelo personalizado (consola)

Para eliminar una implementación de un modelo personalizado

1. En el panel de navegación, en Inferencia y evaluación, elija Modelo personalizado bajo demanda.
2. Elija la implementación de modelo personalizado que desea eliminar.
3. Elija Eliminar.
4. En el cuadro de diálogo de confirmación, introduzca el nombre de la implementación para confirmar la eliminación.
5. Elija Eliminar para confirmar.

El estado de la implementación cambiará a `Deleting` mientras la eliminación esté en curso. Una vez finalizada, la implementación se eliminará de la lista.

Eliminación de la implementación de un modelo (AWS Command Line Interface)

Para eliminar una implementación de modelo personalizado mediante la AWS Command Line Interface, utilice el comando `delete-custom-model-deployment` con su identificador de implementación.

```
aws bedrock delete-custom-model-deployment \
--custom-model-deployment-identifier "deployment-arn-or-name" \
--region region
```

Eliminar una implementación de modelo personalizado (SDK de AWS)

Para eliminar una implementación de modelo personalizada mediante programación, utilice la operación de API de [DeleteCustomModelDeployment](#) con el nombre de recurso de Amazon (ARN) o el nombre de la implementación. El siguiente código muestra cómo utilizar el SDK para Python (Boto3) para eliminar la implementación de un 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
```

Inferencia bajo demanda sobre modelos personalizados

La inferencia bajo demanda (OD) le permite ejecutar inferencias en sus modelos personalizados de Amazon Nova sin mantener los puntos de conexión de rendimiento aprovisionados. Esto ayuda a optimizar los costos y a escalar de manera eficiente. Con la inferencia bajo demanda, se cobra en función del uso, medido en tokens, tanto en entradas como en salidas.

Requisitos de compatibilidad

Se aplican los siguientes requisitos de compatibilidad:

- La inferencia bajo demanda se admite para los modelos de comprensión personalizados de Amazon Nova Pro, Lite y Micro. La inferencia OD no es compatible con los modelos de generación de contenido personalizados de Nova.
- La inferencia OD es compatible con los modelos de comprensión personalizados de Amazon Nova entrenados después del 16 de julio de 2025. Los modelos personalizados entrenados antes del 16 de julio de 2025 no son compatibles con la inferencia OD.
- Personalización de Amazon Bedrock: la inferencia OD es compatible con los modelos personalizados con la personalización de Amazon Bedrock y para los modelos aprendiz que se extrajeron de un modelo instructor con Amazon Bedrock.
- Personalización de SageMaker AI: para los modelos personalizados en SageMaker AI, la inferencia OD solo es compatible con los modelos afinados con eficiencia de parámetros (PEFT) cuando el modelo está alojado en Amazon Bedrock. Esto incluye la optimización directa de preferencias más el PEFT. La inferencia OD no es compatible con los modelos de ajuste fino de rango completo.

Entrenamiento del modelo e inferencia

Cuando entrene un nuevo modelo Amazon Nova Pro, Lite o Micro personalizado en Amazon Bedrock o SageMaker AI mediante PEFT después del 16 de julio de 2025, dicho modelo será automáticamente compatible con las opciones de inferencia aprovisionadas y bajo demanda. Puede seleccionar el método de inferencia que prefiera durante la implementación del modelo.

Para utilizar la inferencia OD con un modelo entrenado después del 16 de julio de 2025, complete los siguientes pasos:

1. Cree un nuevo trabajo de afinación con la API de personalización de [Amazon Bedrock o la API de personalización de SageMaker AI](#).
2. Implemente el modelo recién entrenado en Amazon Bedrock mediante la [API de CreateCustomModel](#).
3. Realice la implementación para realizar inferencias bajo demanda mediante la API de CustomModelDeployment.

Límites de frecuencia

Los siguientes límites de solicitudes por minuto (RPM) y de tokens por minuto (TPM) se aplican a las solicitudes de inferencia bajo 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 obtener más información acerca de las cuotas disponibles para Amazon Nova, consulte [Cuotas para Amazon Nova](#).

Latencia

Puede esperar una diferencia de latencia de extremo a extremo (es decir, el tiempo transcurrido hasta el primer token [TTFT]) del 20 al 55 % entre la invocación del modelo base y el adaptador. El valor exacto de latencia varía según el tamaño del modelo y está en concordancia con los estándares del sector.

Limitaciones de la personalización de los modelos de Amazon Nova

La personalización de Amazon Nova no admite las siguientes capacidades en SageMaker.

- SSH en la instancia para encontrar las métricas

Debido a los controles de seguridad en vigor, no puede utilizar SSH en el nodo maestro de la instancia de entrenamiento algo-1 para buscar estadísticas de memoria o estadísticas de NVIDIA y validar los pasos de entrenamiento.

- Compatibilidad con el SDK de entrenador de SageMaker

El entrenador de SageMaker no está disponible actualmente para iniciar trabajos de entrenamiento. Actualmente solo puede iniciar trabajos de entrenamiento a través de la API del estimador.

- Los grupos en caliente no pueden acceder a los trabajos de entrenamiento de SageMaker

Debido a los controles de seguridad en vigor, los grupos en caliente de SageMaker no se pueden utilizar para mantener la instancia en el grupo en caliente hasta el momento de su expiración.

- Combinación de modelos personalizados

Actualmente, no se admite la combinación de varios modelos. Esto significa que no es posible crear varios adaptadores LoRA ni realizar una operación de combinación múltiple con el modelo base.

- Herramienta de observabilidad compatible

[TensorBoard](#) es la única herramienta de observabilidad compatible para ver las métricas de los trabajos de entrenamiento de SageMaker. [MLFlow](#) o [WandB](#) no son compatibles actualmente. Para obtener más información sobre el uso de TensorBoard en SageMaker, consulte [TensorBoard en SageMaker](#).

Amazon Nova Forge

Amazon Nova Forge es un servicio pionero que ofrece a las organizaciones la forma más fácil y rentable de crear sus propios modelos de frontera con Nova.

Amazon Nova Forge presenta el concepto de modelos de “entrenamiento abierto”, los cuales ofrecen a las organizaciones acceso a varios de puntos de control de modelo iniciales y la capacidad de combinar datos patentados con conjuntos de datos seleccionados por Amazon en cada etapa del entrenamiento del modelo. Esto permite que los modelos maximicen el aprendizaje a partir de datos patentados y, al mismo tiempo, minimicen el riesgo de olvidar habilidades fundamentales como el razonamiento.

Nova Forge le permite hacer lo siguiente:

- Acceder a los puntos de control en todas las fases del desarrollo del modelo y usar los nuevos modelos de Nova antes de que estén disponibles de forma general.
- Combinar sus datos patentados con los datos de entrenamiento seleccionados por Amazon Nova.
- Realizar un aprendizaje por refuerzo con funciones de recompensa en su entorno.
- Usar fórmulas optimizadas con solo pulsar un botón para crear con Nova mediante flujos de trabajo visuales o una interfaz de línea de comandos
- Utilice el kit de herramientas de IA responsable para adaptar los modelos a las directrices de IA responsable de Amazon Nova durante el proceso de entrenamiento e implementar controles de tiempo de ejecución para moderar las respuestas de los modelos durante la inferencia.

Requisitos previos

Temas

- [Suscripción a Nova Forge](#)
- [Otros requisitos previos](#)

Suscripción a Nova Forge

Para solicitar acceso al servicio Amazon Nova Forge, agregue la siguiente etiqueta al rol de IAM de la consola: clave forge-subscription con el valor true. Tras agregar esta etiqueta a su rol, vaya a la consola de SageMaker AI > Entrenamiento y personalización de modelos y haga clic en Nova Forge.

En esta página, encontrará detalles sobre el servicio, información sobre precios y funciones. Puede solicitar la suscripción y, a continuación, administrarla desde esta página.

1. El rol debe tener permiso para llamar a la API `ListAttachedRolePolicy` y la respuesta debe incluir una política `AmazonSageMakerFullAccess` o una política `AdministratorAccess`.
2. El rol de inicio de sesión debe tener permiso para llamar a la API `ListRoleTags` y las etiquetas de respuesta deben incluir `tag.key=forge-subscription`.

Otros requisitos previos

Asegúrese también de que se cumplen los siguientes requisitos previos:

1. [Requisitos previos generales](#)
2. Pasos adicionales para los usuarios: agregar un grupo de instancias restringido (RIG) al clúster de SageMaker HyperPod (para hacerlo, [siga estos pasos](#))

Acceso a Nova Forge y configuración

Para acceder a Nova Forge, siga este proceso de 2 pasos:

- Paso 1: suscripción a Nova Forge
- Paso 2: configuración de la infraestructura de HyperPod

Obtención de los documentos de Nova Forge

Para obtener los documentos de Nova Forge, siga los pasos que se indican a continuación:

```
mkdir NovaForgeHyperpodCLI
cd NovaForgeHyperpodCLI
aws s3 cp s3://nova-forge-c7363-206080352451-us-east-1/v1/ ./ --recursive
pip install -e .
```

Paso 1: suscripción a Nova Forge

Resumen rápido:

1. Compruebe que tiene acceso de administrador a la cuenta de Amazon Web Services.

2. Vaya a la consola de SageMaker AI y solicite acceso a Nova Forge.
3. Espere a que el equipo de Nova envíe una confirmación por correo electrónico una vez aprobada la solicitud de suscripción.
4. Etiquete el rol de puesta en marcha con la etiqueta `forge-subscription`. Esta etiqueta es necesaria para acceder a las características y puntos de control de Nova Forge. Agregue la siguiente etiqueta al rol de puesta en marcha:
 - Clave: `forge-subscription`
 - Valor: `true`

Guía detallada

Para suscribirse a Nova Forge y utilizar el servicio de personalización de forma eficaz, un cliente de Amazon Web Services debe tener acceso de administrador a su cuenta de Amazon Web Services o pedir a un administrador que le conceda acceso de administrador. Este documento describe los pasos necesarios para:

- Obtener acceso de administrador
- Configurar políticas para suscribirse a Nova Forge
- Acceder a fórmulas de personalización
- Configurar la personalización
- Supervisar el flujo de trabajo
- Evaluar el punto de control del modelo personalizado

Opción A

Flujo 1: el usuario debe ponerse en contacto con el administrador de la cuenta para solicitar lo siguiente:

- Agregar la etiqueta `forge-subscription` etiqueta a la cuenta a través de IAM (consulte el Apéndice A para ver los pasos que se deben seguir).
- Agregar los permisos `ListRoleTags` y `ListAttachedRolePolicies` a través de IAM (consulte el Apéndice B para ver los pasos que se deben seguir).

 **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

[Request subscription](#)[Documentation](#)

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.

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

Opción B

Flujo: el usuario debe ponerse en contacto con el administrador de la cuenta para solicitar acceso de administrador a la cuenta.

- Una vez que se haya concedido el acceso de administrador, siga los pasos del flujo 2.

Flujo 2. Cuenta de Amazon Web Services con acceso de administrador

- Agregue la etiqueta forge-subscription a la cuenta a través de IAM. Consulte los pasos del Apéndice A

Apéndice A. Adición de una política de forge-subscription a la cuenta de Amazon Web Services

1. Vaya al panel de IAM de Amazon Web Services. Haga clic en Roles a la izquierda. Busque administrador y haga clic en el rol 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

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 1 match

Role name	Trusted
libsAdminAccess-DO-NOT-DELETE	Account:

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 Aut](#) to authenticate identities.

2. Seleccione <AssumedRoleToUse> (por ejemplo, libsAdminAccess). Haga clic en la pestaña Etiquetas.

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

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

Tags (2) [Info](#)


Tags are key-value pairs that you can add to AWS resources to help identify,

Key
forge-subscription

- Haga clic en Administrar etiquetas. Agregue una etiqueta nueva. Escriba “forge-subscription” en Clave y haga clic en Guardar cambios




- Asegúrese de ver forge-subscription como clave en la sección Etiquetas




Apéndice B. Adición de las políticas ListRoleTags y ListAttachedPolicies a la cuenta de Amazon Web Services para que el administrador desempeñe un rol ajeno al de administrador

1. Vaya al panel de IAM de Amazon Web Services. Haga clic en Roles a la izquierda. Busque <AssumedRoleToUse> (por ejemplo, ForgeAccessRole) y haga clic en el rol <AssumedRoleToUse> (por ejemplo, ForgeAccessRole).




2. Haga clic en el rol <AssumedRoleToUse> (por ejemplo, ForgeAccessRole) y seleccione Etiquetas. Agregue una nueva etiqueta con el tipo “forge-subscription”.



3. En Permisos, agregue un nuevo permiso: Agregar permisos → Crear política insertada → Agregue la política que se indica a continuación:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "VisualEditor0",
      "Effect": "Allow",
      "Action": [
        "iam:ListRoleTags",
        "iam:ListAttachedRolePolicies"
      ],
      "Resource": "*"
    }
  ]
}
```



Paso 2. Configuración de la infraestructura de HyperPod

Configure la infraestructura necesaria siguiendo las [instrucciones del taller](#) para configurar el entorno con características compatibles con Forge.

Configuración de moderación de contenido

Si necesita acceso a Nova Forge, puede usar la configuración de moderación de contenido personalizable (CCMS) para los modelos de Amazon Nova Lite 1.0 y Pro 1.0. La CCMS le permite ajustar los controles de moderación de contenido para adaptarlos a sus requisitos empresariales específicos y, al mismo tiempo, mantener las medidas de protección esenciales y específicas de la IA responsable. Para determinar si un modelo de negocio es adecuado para la CCMS, contacte con un administrador de cuentas de AWS.

Para obtener información adicional sobre la configuración y el uso del CCMS con modelos personalizados, consulte la sección [Responsible AI Toolkit and Content Moderation section](#).

Entrenamiento previo continuo y entrenamiento intermedio

Note

Recibirá la documentación detallada cuando se suscriba.

El CPT de Nova Forge ofrece capacidades avanzadas que van más allá del CPT estándar, como el acceso a puntos de control intermedios y la combinación de datos con el corpus de entrenamiento previo de Nova. Estas características permiten una adaptación más eficiente al dominio y una mejor conservación de las capacidades generales del modelo.

¿Qué son los puntos de control intermedios y por qué son necesarios?

Los puntos de control intermedios son instantáneas del modelo Amazon Nova guardadas en diferentes etapas del entrenamiento previo, antes de que el modelo alcance su estado final listo para la producción. Durante el desarrollo del modelo, Amazon Nova se somete a varias fases de entrenamiento: entrenamiento previo inicial con un ritmo de aprendizaje constante, reducción del ritmo de aprendizaje, entrenamiento con ampliación del contexto y, por último, adaptación orientada al seguimiento de instrucciones y entrenamiento en seguridad. En el CPT, los puntos de control intermedios suelen ser preferibles al punto de control final de producción, ya que son más plásticos y receptivos a la adaptación al dominio. El punto de control de producción se ha sometido a una amplia adaptación para seguir instrucciones y a un riguroso entrenamiento en seguridad, lo que optimiza el modelo para un uso conversacional general, pero puede hacer que se resista a aprender nuevos patrones específicos de un dominio durante el CPT. En cambio, los puntos de control de solo texto parcial y completamente preentrenados retienen las características del modelo antes del entrenamiento. No cuentan con una orientación marcada hacia comportamientos específicos, lo que los convierte en puntos de partida más eficientes para la adaptación al dominio. Al realizar un CPT a gran escala (más de 10 000 millones de tokens), partir de puntos de control intermedios suele dar como resultado una convergencia más rápida, un entrenamiento más constante y una adquisición más eficaz del conocimiento del dominio. Sin embargo, en el caso del CPT a pequeña escala (menos de 10 000 millones de tokens), o cuando sea necesario conservar las capacidades de seguimiento de instrucciones, el punto de control de producción puede ser más apropiado, ya que permite la adaptación al dominio y, al mismo tiempo, mantiene las capacidades de conversación del modelo.

El CPT necesita varios puntos de control intermedios, ya que ofrecen diferentes niveles de plasticidad del modelo que repercuten en la eficiencia con la que el modelo puede absorber nuevos conocimientos del dominio. El punto de control final de producción se ha sometido a una amplia adaptación para seguir instrucciones y a un riguroso entrenamiento en seguridad, lo que optimiza el modelo para un uso conversacional general, pero hace que este se resista a aprender nuevos patrones específicos de un dominio. En otras palabras, se ha ido endureciendo a través del entrenamiento posterior. En cambio, los puntos de control anteriores retienen las características previas al entrenamiento del modelo y no se han centrado demasiado en comportamientos específicos, lo que los hace más plásticos y receptivos a la adaptación al dominio.

Para lograr la máxima eficiencia en el entrenamiento, se proporcionan varios puntos de control intermedios.

¿Qué puntos de control hay disponibles?

Nova 2.0

Hay tres puntos de control de Amazon Nova Lite 2.0:

- **PRE-TRAINED** [nova-lite-2/pretraining-text-RD]: este es el punto de control tras el ritmo de aprendizaje constante y las etapas de reducción del entrenamiento previo de Amazon Nova, en las que el modelo se entrena con billones de tokens.
- **MID-TRAINED** [nova-lite-2/pretraining-text-CE]: este punto de control permite introducir volúmenes intermedios de datos no estructurados con un ritmo de aprendizaje más conservador que el del entrenamiento previo, lo que permite integrar conocimiento específico del dominio y evitar el olvido catastrófico.
- **POST-TRAINED** [nova-lite-2/prod]: este es el punto de control final totalmente adaptado del modelo, que ha seguido todos los pasos pertinentes y posteriores del entrenamiento.

La siguiente tabla detalla las diferentes condiciones para el entrenamiento previo e intermedio.

Tipo de datos	Realización	Con punto de control
Datos de dominio sin procesar no estructurados a gran escala (documentos, registros, artículos, código, etc.)	Entrenamiento previo continuo	Entrenamiento previo

Tipo de datos	Realización	Con punto de control
Datos de dominio sin procesar no estructurados a gran escala (documentos, registros, artículos, código, etc.)	Entrenamiento intermedio	Entrenamiento previo
Volúmenes más pequeños de datos sin procesar no estructurados. Rastros de razonamiento estructurado y datos de CoT	Entrenamiento intermedio	Entrenamiento intermedio
Demostraciones estructuradas (pares de entradas y salidas de alta calidad, instrucciones de tareas seleccionadas, diálogos de varios turnos)	Refinamiento completo	Entrenamiento intermedio
Demostraciones estructuradas (pares de entradas y salidas de alta calidad, instrucciones de tareas seleccionadas, diálogos de varios turnos)	Refinamiento eficiente de parámetros (PEFT)	Entrenamiento posterior

¿Qué punto de control usar?

Los puntos de control de solo texto parcial y completamente preentrenados suelen converger más rápido y requieren menos pasos de entrenamiento para la adaptación al dominio. Sin embargo, no cuentan con refinamiento mediante instrucciones y necesitarían someterse a etapas posteriores de entrenamiento para poder realizar tareas útiles y seguir instrucciones. Es posible que el punto de control de disponibilidad general requiera más pasos para adaptarse, pero proporciona un punto de partida más seguro para experimentos a pequeña escala y mantendrá algunas de sus capacidades posteriores al entrenamiento incluso después del entrenamiento con CPT.

Por lo general, si se trata de conjuntos de datos de entrenamiento de gran tamaño (más de 10 000 millones de tokens), se debe empezar por puntos de control que contengan solo texto preentrenados

parcial o totalmente para lograr un entrenamiento más eficiente y estable, ya que la base de conocimientos del modelo se modificará sustancialmente. Con conjuntos de datos pequeños (menos de 10 000 millones de tokens), utilice el punto de control de disponibilidad general para conservar la capacidad de seguir las instrucciones y, al mismo tiempo, adaptarse al dominio.

¿Cómo se utiliza la mezcla de datos para Nova 2.0?

Al realizar el CPT con datos de un dominio nuevo, resulta muy beneficioso mezclar los nuevos datos con algunos de los datos utilizados anteriormente en la fase de entrenamiento previo del modelo. La mezcla de datos antiguos con datos de dominio nuevos resuelve dos problemas:

- **Control sobre olvidos:** evita un olvido catastrófico al preservar las habilidades y los conocimientos existentes del modelo. Si no se combinan los datos, el entrenamiento exclusivo con datos de dominio limitado hace que el modelo sobrescriba las capacidades generales. Por ejemplo, un modelo entrenado únicamente con documentos legales podría perder su capacidad para programar o realizar operaciones matemáticas. Al mezclar conjuntos de datos de dominio general, se conservan estas habilidades generales mientras se adquiere un nuevo dominio.
- **Estabilidad de la optimización:** mantiene la estabilidad del entrenamiento anclando las representaciones internas del modelo. Durante el CPT, las características aprendidas del modelo se modifican y la mezcla de datos proporciona gradientes de diversos orígenes que guían esta adaptación sin problemas. Sin este mecanismo, entrenar sobre distribuciones estrechas puede provocar inestabilidad en los gradientes, haciendo que las representaciones del modelo cambien de forma demasiado drástica y dando lugar a divergencia en el entrenamiento, picos en la pérdida o colapso de capacidades existentes. Esta es la disyuntiva entre estabilidad y plasticidad: el modelo debe ser lo suficientemente plástico como para aprender nuevos conocimientos, pero lo suficientemente estable como para olvidar o corromper lo que ya conoce.

Capacidades de mezcla de datos del CPT de Nova

El acceso a los datos y puntos de control de entrenamiento previo de Amazon Nova es una de las principales ofertas de personalización del CPT de Amazon Nova. La personalización del CPT de Amazon Nova permite mezclar fácilmente los datos de dominio con el corpus de entrenamiento previo de Amazon Nova. Además, la proporción de muestras de las categorías de datos específicas de Amazon Nova (por ejemplo, código, matemáticas, razonamiento, etc.) se puede cambiar y sus proporciones se pueden controlar para complementar los datos de dominio. Esto permite reforzar las capacidades para adaptarlas a casos de uso concretos y, al mismo tiempo, adaptar el modelo al dominio específico.

Cómo lograr la proporción de mezcla óptima

La proporción óptima entre los datos de Amazon Nova y los datos de dominio depende del dominio, la complejidad, el tamaño y la calidad del conjunto de datos y de la importancia de mantener las capacidades generales. Esta proporción debe descubrirse mediante la experimentación. El siguiente es un marco experimental para determinar la cantidad de datos de Amazon Nova que se van a mezclar.

Seleccione un subconjunto representativo de datos de dominio (por ejemplo, 5000 millones de tokens) y manténgalo constante en todas las iteraciones experimentales.

Realice experimentos de CPT a pequeña escala variando solo la cantidad de datos de Amazon Nova mezclados:

- Sin mezcla: 100 % datos de dominio → 5000 millones de datos de dominio únicamente (5000 millones en total)
- Poca mezcla: 90 % datos de dominio → 5000 millones de datos de dominio + ~560 millones de datos de Amazon Nova (~5560 millones en total)
- Mezcla intermedia: 70 % datos de dominio → 5000 millones de datos de dominio + ~2140 millones de datos de Amazon Nova (~7140 millones en total)
- Mezcla importante: 50 % datos de dominio → 5000 millones de datos de dominio + 5000 millones de datos de Amazon Nova (10 000 millones en total)

Evalúe cada punto de control en función de los pruebas comparativas internas y generales del dominio. Evalúe también el punto de control inicial (punto de control de Amazon Nova antes de cualquier entrenamiento).

- ¿El rendimiento del dominio del cliente se mantiene prácticamente constante a lo largo de las iteraciones? Por lo general, debería ser así, ya que en cada iteración se utilizó la misma cantidad de tokens de dominio. Si el rendimiento del dominio mejora con una mayor mezcla, los datos de Amazon Nova proporcionan una regularización útil.
- ¿Mejoran las puntuaciones de referencia generales a medida que aumenta la mezcla?
 - El comportamiento esperado es que las capacidades generales mejoren monótonamente conforme se agreguen más datos de Amazon Nova.
 - Haga pruebas comparativas generales para medir los resultados: MMLU (conocimientos generales), HumanEval (programación), GSM8K (matemáticas) o pruebas comparativas específicas de interés.

- Seleccione la proporción de mezcla que garantice un buen rendimiento en el dominio, ofrezca capacidades generales aceptables para distintos casos de uso. Tenga en cuenta el costo adicional del entrenamiento y mezcle más datos.

Cuando se haya identificado la proporción de mezcla óptima, lleve a cabo el CPT a gran escala utilizando el conjunto de datos de dominio completo con la proporción de mezcla seleccionada.

Análisis de las categorías de mezcla de datos

A continuación, analizamos cada categoría disponible en la mezcla de datos para que pueda tomar la mejor decisión sobre qué categorías de datos deberían participar en la mezcla de datos general.

¿Cómo habilitar la mezcla de datos?

Agregue la sección `data_mixing` a la fórmula con la distribución porcentual adecuada entre las categorías del conjunto de datos. La suma de los porcentajes de `nova_data` debe ser 100.

Configuración de Nova 2.0 con la mezcla de datos

```
# 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

```

Qué significan estas categorías

Nota: Nova 2.0 incluye categorías adicionales específicas de su capacidad de razonamiento (por ejemplo, `reasoning-code`, `reasoning-math` y `reasoning-instruction-following`) que no están disponibles en Nova 1.0.

Resumen de categorías y etiquetas informativas:

Nombre de la categoría	Información
<code>agents</code>	Datos de entrenamiento centrados en la toma de decisiones autónoma, la finalización de tareas y el comportamiento orientado a los objetivos en los sistemas de IA.
<code>baseline</code>	Datos lingüísticos fundamentales centrados en la comprensión general, la comunicación básica y las capacidades lingüísticas troncales.
<code>chat</code>	Intercambios conversacionales que muestran el flujo natural del diálogo, un contexto coherente a lo largo de todo el intercambio y las interacciones sociales apropiadas.
<code>code</code>	Código fuente de programación, documentación y debates técnicos que abarcan diversos lenguajes de programación y plataformas.
<code>factuality</code>	Información verificada y materiales de referencia centrados en la precisión, la validación de fuentes y la evaluación de la veracidad.

Nombre de la categoría	Información
<code>identity</code>	Marcos de personalidad y patrones de comportamiento centrados en rasgos de carácter, valores y estilos de interacción consistentes.
<code>long-context</code>	Narrativas complejas y textos extensos centrados en mantener la coherencia y la relevancia en largos intercambios.
<code>math</code>	Contenido matemático que incluye libros de texto, problemas, soluciones y debates matemáticos.
<code>rai</code>	Casos y escenarios que enfatizan los principios de la IA ética, los aspectos que se deben tener en cuenta en materia de seguridad y la implementación responsable de la tecnología.
<code>instruction-following</code>	Ejemplos de pasos precisos para completar tareas en función de distintos niveles de peticiones e indicaciones del usuario.
<code>stem</code>	Contenido técnico sobre ciencia, tecnología, ingeniería y matemáticas, incluidos conceptos teóricos y de resolución de problemas.
<code>planning</code>	Secuencias que demuestran el pensamiento estratégico, el desglose paso a paso de las tareas y la asignación eficiente de los recursos.
<code>reasoning-chat</code>	Escenarios de diálogo analítico centrados en el debate lógico y los flujos de conversación estructurados.
<code>reasoning-code</code>	Desafíos de programación y problemas algorítmicos centrados en el desarrollo sistemático de soluciones.
<code>reasoning-factuality</code>	Escenarios de evaluación de la información centrados en los procesos críticos de evaluación y verificación.
<code>reasoning-instruction-following</code>	Análisis de tareas complejas centrado en la interpretación sistemática y la realización de tareas de forma metódica.

Nombre de la categoría	Información
reasoning-math	Escenarios matemáticos de resolución de problemas centrados en la progresión lógica y las estrategias de solución.
reasoning-planning	Escenarios de toma de decisiones estratégicas centrados en un enfoque sistemático para el cumplimiento de objetivos.
reasoning-rag	Escenarios de recuperación y síntesis de información centrados en la comprensión contextual y la aplicación pertinente.
reasoning-rai	Escenarios de toma de decisiones éticas centrados en la evaluación sistemática de la seguridad y la equidad de la IA.
reasoning-stem	Escenarios científicos de resolución de problemas centrados en el análisis metódico y el desarrollo de soluciones.
rag	Ejemplos de cómo combinar eficazmente el conocimiento externo recuperado con las respuestas generadas para proporcionar información contextual precisa.
translation	Combinaciones de contenido multilingüe que muestran una traducción precisa y, al mismo tiempo, conservan el contexto, el tono y los matices culturales.

Guía de parámetros

- `dataset_catalog`: el único valor es `cpt_text_lite` por ahora, hasta que habilitemos el entrenamiento multimodal.
- `nova_data`: porcentaje de las categorías individuales de datos de Nova cuando se mezclan. Deberían sumar 1,0.
- `customer_data`: el porcentaje de datos del cliente mezclados con los datos de Nova.

El número total de tokens utilizados en el entrenamiento se puede calcular de esta forma:

`max_length * global_batch_size * max_steps`

Limitaciones

El CPT actual solo admite datos de texto y no admite ningún conjunto de datos multimodales de clientes.

Refinamiento supervisado

Introducción

El refinamiento supervisado utiliza un conjunto de datos con pares de entrada-salida para la tarea de interés. En otras palabras, se proporcionan ejemplos de peticiones (preguntas, instrucciones, etc.) junto con las respuestas correctas o deseadas y se usan para seguir entrenando el modelo. Las ponderaciones del modelo se ajustan para minimizar una pérdida supervisada, que suele ser una entropía cruzada entre sus predicciones y los tokens de respuesta objetivo.

¿Cuándo se debe usar SFT?

SFT es mejor cuando tiene una tarea bien definida con los resultados deseados claros. Si puede decir explícitamente “Con una entrada X, la salida correcta o deseada es Y” y puede recopilar ejemplos de este tipo de asignaciones X-Y, entonces el refinamiento supervisado es una buena opción. Algunos escenarios en los que el SFT sobresale son los siguientes:

- Tareas de clasificación estructuradas o complejas: por ejemplo, clasificar los documentos internos o los contratos en muchas categorías personalizadas. Con el SFT, el modelo puede aprender estas categorías específicas mucho mejor que con peticiones por sí solas.
- Tareas de respuesta a preguntas o de transformación con respuestas conocidas: por ejemplo, refinar un modelo para que responda a preguntas de la base de conocimientos de una empresa o convertir datos de un formato a otro, en el que cada entrada tenga una respuesta correcta.
- Formato y estilo consistentes: si necesita que el modelo responda siempre en un formato o tono determinado, puede refinar los ejemplos del formato o tono correctos. Por ejemplo, si se entrena con pares de petición-respuesta que reflejan la voz o el estilo de una marca en particular, se puede enseñar al modelo a que use ese estilo en sus resultados. El comportamiento orientado al seguimiento de instrucciones suele enseñarse inicialmente con el SFT, usando ejemplos seleccionados que demuestran cómo debe comportarse un buen asistente.

El SFT es la forma más directa de enseñarle a un LLM una nueva habilidad o comportamiento cuando se puede especificar cuál es el comportamiento correcto. Aprovecha la comprensión lingüística existente del modelo y la centra en la tarea. No utilice el SFT cuando la brecha se deba al

conocimiento y no al comportamiento; no hará que el modelo aprenda nuevos datos, jerga o eventos recientes. En esos casos, es preferible el entrenamiento previo continuo con grandes corpus propios del dominio o generación aumentada con recuperación para integrar conocimiento externo durante el proceso de inferencia. Si se puede medir la calidad, pero no se puede etiquetar una sola respuesta correcta, el refinamiento por refuerzo con recompensas verificables o con LLM como juez puede ser preferible en lugar del SFT.

En función de la complejidad de las tareas y del rendimiento del modelo de Nova sin necesidad de realizar ajustes, planifique entre miles y decenas de miles de demostraciones por tarea, en las que la calidad, la coherencia y la diversidad de los datos sean más importantes que el volumen bruto.

¿Cuándo usar un SFT que haga un uso eficiente de los parámetros y cuándo usar un SFT de rango completo?

Las fórmulas de personalización de Nova le permiten hacer un uso eficiente de los parámetros, en particular en el SFT LoRA o de rango completo. Si desea actualizar el modelo de forma sencilla y rentable, o si dispone de muy pocos datos, opte por métodos eficientes en cuanto a parámetros, de forma que se entrenen adaptadores pequeños y se deje intacta la mayor parte de la estructura básica (el SFT de rango completo actualiza todos los parámetros del modelo).

Mezcla de datos para el SFT

La mezcla de datos le permite combinar sus conjuntos de datos de entrenamiento personalizados con los datos de entrenamiento patentados de Nova. Esta característica está disponible para los modelos de Nova 1.0 y Nova 2.0.

Tipo de datos patentados de Nova: Nova admite tipos de datos multimodales y de texto para el SFT. Se organizan en varias categorías de datos, cada una de las cuales contiene una combinación de tareas relevantes para la categoría correspondiente.

Categorías de datos propias patentados de Nova: los conjuntos de datos de texto incluyen varias categorías, como: toma de decisiones autónoma, finalización de tareas, conjuntos de datos orientados a objetivos (agentes), conjuntos de datos de finalización de tareas precisas tanto con razonamiento como sin razonamiento (reasoning-instruction-following, instruction-following), secuencias que demuestran el pensamiento estratégico y el desglose paso a paso de tareas (planificación), IA responsable (rai), contexto largo, factualidad, matemáticas, STEM y muchas más. Del mismo modo, los conjuntos de datos multimodales incluyen video, captura de pantalla, gráficos y muchos más.

La característica de mezcla de datos le permite combinar sus propias muestras de entrenamiento con refinamiento con muestras de los conjuntos de datos de Nova que se utilizan para refinar el modelo de Nova. Esto puede evitar el sobreajuste en el entrenamiento personalizado y el “olvido catastrófico” de las capacidades de Nova, o ser de ayuda para desarrollar capacidades cuando entrene desde un nuevo punto de control previamente entrenado.

Para mezclar los datos de Nova, solo tiene que agregar un bloque `data_mixing` al archivo YAML de su fórmula, en la sección `training_config`. Los bloques de mezcla de datos multimodales y de texto tienen un contenido diferente. Consulte las fórmulas correspondientes.

Modelos compatibles

- Nova 2.0 Lite

Modalidad admitida

- Texto
- Multimodal

Ejemplos de configuración de YAML

Ejemplo de configuración de 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
```

Mezcla de datos de texto de 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
```

Mezcla de datos multimodales de 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
```

Puntos de control del modelo

Puntos de control de Nova 2.0

- PRE-TRAINED [nova-lite-2/pretraining-text-RD]: punto de control tras el ritmo de aprendizaje constante y las etapas de reducción en las que el modelo se entrena con billones de tokens. [Resultado de la etapa 2]
- MID-TRAINED [nova-lite-2/pretraining-text-CE]: permite a los clientes con volúmenes intermedios de datos no estructurados introducir sus datos con un ritmo de aprendizaje más conservador que el del entrenamiento previo, lo que permite integrar conocimiento específico del dominio y evitar el olvido catastrófico. [Resultado de la etapa 3]
- FINAL [nova-lite-2/prod]: punto de control final totalmente adaptado que ha pasado por todas las etapas de entrenamiento previo y posterior. [Resultado de la etapa 4]

Etapas de entrenamiento:

- Etapa 1: punto de control de entrenamiento previo, entrenamiento previo inicial con un ritmo de aprendizaje constante
- Etapa 2: punto de control de entrenamiento previo, reducción del ritmo de aprendizaje
- Etapa 3: punto de control de entrenamiento previo, entrenamiento con ampliación del contexto
- Etapa 4: adaptación orientada al seguimiento de instrucciones y entrenamiento en seguridad

Estrategias de entrenamiento

Guía de selección de estrategias de entrenamiento

Tipo de datos	Volumen de datos	Realización	Con punto de control
Datos de dominio sin procesar no estructurados a gran escala (documentos, registros, artículos, código, etc.)	Más de 1 billón de tokens	Entrenamiento previo continuo	Fin del ritmo de aprendizaje constante (CLR)
Datos de dominio sin procesar no estructurados a gran escala	Más de 100 000 millones de tokens	Entrenamiento intermedio	Fin del CLR
Volúmenes más pequeños de datos sin procesar no estructurados; trazas de razonamiento estructurado y datos de CoT	Más de 1000 millones de tokens	Entrenamiento intermedio	Modelo base de Nova
Demostraciones estructuradas (pares de entradas y salidas de alta calidad, instrucciones de	Más de 1000 ejemplos	Refinamiento supervisado (SFT)	Modelo base de Nova

Tipo de datos	Volumen de datos	Realización	Con punto de control
tareas seleccionadas, diálogos de varios turnos)			

Requisitos previos antes de empezar

- Supongamos que ya configuró un clúster de SMHP con un grupo de instancias restringido (RIG) que tiene capacidad activa. De lo contrario, consulte aquí para completar la configuración del clúster y el RIG de SMHP [[enlace a la documentación](#), [enlace al taller](#)]
- Necesitará instancias de EC2 p5.48xlarge para usar esta fórmula. El número mínimo de instancias necesario para usar esta fórmula de manera eficiente es el siguiente:
 - Nova Lite 2.0: 4 p5.48xlarge
- Instale la CLI de SageMaker HyperPod específica de Forge siguiendo [estas instrucciones](#).
- Confirme que puede conectarse al clúster mediante `hyperpod get-clusters`.
 - Tenga en cuenta que este comando mostrará una lista de todos los clústeres de SMHP de su cuenta.
- Confirme que sus datos de entrenamiento y, opcionalmente, de validación, estén disponibles en un bucket de S3 al que pueda acceder el rol de puesta en marcha de su clúster de SMHP. Para la preparación de los datos, consulte la siguiente sección.
- Complete la configuración de la AWS CLI. Si no ha completado la configuración, siga esta [guía](#).
- Verificación: después de completar la configuración, confirme que puede usar correctamente los siguientes comandos:

```
aws sagemaker describe-cluster --cluster-name <cluster-name> --region <region>

hyperpod connect-cluster --cluster-name cluster-name
```

Un enfoque sistemático para lograr un SFT exitoso

- Preparación de datos: siga las pautas establecidas para crear, limpiar o reformatear conjuntos de datos para adaptarlos a la estructura requerida. Asegúrese de que las entradas, las salidas y la información auxiliar (como las pistas de razonamiento o los metadatos) estén adaptadas y formateadas correctamente.
- Configuración del entrenamiento: defina cómo se entrenará el modelo. Cuando se usa Amazon SageMaker HyperPod, esta configuración se escribe en un archivo de fórmulas YAML que incluye:
 - Rutas de orígenes de datos (conjuntos de datos de entrenamiento y validación)
 - Hiperparámetros clave (número de pasos de entrenamiento, ritmo de aprendizaje, tamaño del lote)
 - Componentes opcionales (parámetros de entrenamiento distribuidos, etc.)
 - Configuración de mezcla de datos (define las proporciones de las categorías de datos de clientes y Nova)
- Optimización de los hiperparámetros del SFT: los valores de los parámetros de la fórmula del SFT que recomendamos son un buen punto de partida y una opción sólida. Si desea optimizarlos aún más para su caso de uso, lleve a cabo varios SFT con diferentes combinaciones de parámetros y elija la mejor. Puede seleccionar combinaciones de parámetros siguiendo el método de optimización de hiperparámetros que prefiera. Un enfoque sencillo consiste en variar el valor de un parámetro (predeterminado * 0,5, predeterminado, predeterminado * 2) y conservar el otro valor predeterminado para los demás parámetros; repita esta operación para cada parámetro que desee optimizar e iterar si es necesario. Los parámetros más relevantes para LoRA son el ritmo de aprendizaje, el alfa (parámetro de escalado), el número de épocas que se debe entrenar y los pasos de preparación; en el caso del rango completo, los principales son el ritmo de aprendizaje, el número de épocas y los pasos de preparación.

Experimentación con el orden y la mezcla de datos

- Si solo tiene datos del SFT (entrenamiento/desarrollo/pruebas) para un conjunto de tareas y solo le importa el rendimiento de las pruebas en estas tareas:
 - Lleve a cabo el SFT sin mezclar en el punto de control [FINAL] de Nova. Utilice los hiperparámetros del SFT predeterminados y, si lo desea, optimícelos para su caso de uso. Supervise las métricas de validación y evalúe los puntos de control intermedios para conjuntos de datos más grandes.

- Si solo tiene datos del SFT (entrenamiento/desarrollo/pruebas) para un conjunto de tareas y le importa el rendimiento de las pruebas en estas tareas y las pruebas comparativas generales en el ámbito de interés:
 - Comience por llevar a cabo el SFT con la mezcla de datos de Nova en un punto de control de entrenamiento previo (punto de control PRE-TRAINED o MID-TRAINED, no FINAL). El uso de un punto de control intermedio permite al modelo integrar mejor sus datos personalizados con los datos patentados de Nova y, al mismo tiempo, conservar unas buenas capacidades generales.
 - Realice sesiones de entrenamiento con SFT más cortas con una cantidad variable de datos de Nova (por ejemplo, el 10 %, el 25 %, el 50 % o el 75 %) y selecciones de categorías de datos de Nova que complementen su caso de uso (por ejemplo, elija la categoría de seguimiento de instrucciones si le interesa la habilidad de seguir instrucciones generales). Supervise las métricas de validación y evalúe si la mezcla mejora el rendimiento en las pruebas comparativas generales. Seleccione la combinación de entrenamiento y el punto de control que logren el mejor rendimiento, tanto en general como para una tarea específica. Según el caso de uso, tanto el rendimiento general como el específico para ciertas tareas se pueden mejorar aún más mediante el refinamiento por refuerzo (RFT).

Preparación del conjunto de datos para el SFT

Nova 2.0: utilice el formato de la API de Converse <https://docs.aws.amazon.com/bedrock/latest/userguide/conversation-inference-call.html>. El formato de datos de Nova 2.0 puede contener campos de razonamiento adicionales: https://docs.aws.amazon.com/bedrock/latest/APIReference/API_runtime_ReasoningContentBlock.html

El contenido de razonamiento captura los pasos de pensamiento intermedios del modelo antes de generar una respuesta final. En el turno de assistant, use el campo `reasoningContent` para incluir los rastros de razonamiento. Use texto sin formato para el contenido de razonamiento, evite las etiquetas de marcado como `<thinking>` y `</thinking>` (a menos que la tarea las requiera específicamente) y asegúrese de que el contenido de razonamiento sea claro y relevante para el proceso de resolución de problemas.

Métodos de evaluación

Requisitos previos

- URI del punto de control de S3 del archivo `manifest.json` de su trabajo de entrenamiento (para modelos entrenados)
- Conjunto de datos de evaluación cargado en S3 en el formato correcto
- Ruta de S3 para ver los resultados de la evaluación

Pruebas comparativas listas para usar: utilice pruebas comparativas listas para usar para validar el rendimiento en tareas generales. Para obtener más información, consulte: <https://docs.aws.amazon.com/sagemaker/latest/dg/nova-hp-evaluate.html>

Uso de sus propios datos

También puede usar sus datos personalizados editándolos para que sigan el formato que se muestra más abajo y, luego, utilizando los contenedores mencionados a continuación para obtener los resultados de las inferencias junto con las probabilidades logarítmicas de las calibraciones, si es necesario.

Cree jsonl por tarea con la siguiente estructura:

```
{
  "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"
}
```

Los resultados generados durante la fase de inferencia del trabajo de evaluación tendrán la siguiente estructura:

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

Descripción de campos:

- **prompt**: entrada formateada enviada al modelo
- **inference**: respuesta generada por el modelo
- **gold**: respuesta correcta esperada del conjunto de datos de entrada, campo de respuesta de la entrada
- **metadata**: metadatos opcionales transferidos desde la entrada

Preparación de la configuración de evaluación

Comando para iniciar el trabajo de evaluación. Use "--override-parameters" para modificar cualquier entrada de la 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"  
  }'
```

Prácticas recomendadas

- Priorice la calidad de los datos por encima del volumen: los datos de entrenamiento de alta calidad, diversos y representativos son más valiosos que las grandes cantidades de datos de baja calidad.
- Incluya la categoría reasoning-instruction-following: cuando utilice la combinación de datos, incluya la categoría para mantener un rendimiento genérico sólido en todas las tareas.

- Use ritmos de aprendizaje predeterminados: comience con los ritmos de aprendizaje predeterminados (1e-5 para LoRA, 5e-6 para el SFT de rango completo) y ajústelos solo si es necesario en función de las métricas de validación.
- Equilibre la mezcla de datos de Nova: mezcle un máximo del 50 % de los datos de Nova para lograr un equilibrio óptimo entre latencia y rendimiento. Los porcentajes más altos pueden mejorar las capacidades generales, pero también pueden aumentar el tiempo de entrenamiento.
- Supervise las métricas de validación: evalúe periódicamente los puntos de control intermedios durante el entrenamiento para detectar el sobreajuste o la degradación del rendimiento de forma temprana.
- Realice pruebas con conjuntos de datos representativos: asegúrese de que los conjuntos de datos de evaluación representen con precisión sus casos de uso de producción para evaluar el rendimiento de manera significativa.

Configuración de la preparación de trabajos de entrenamiento

Hiperparámetros

Conjunto completo de hiperparámetros distintos de la mezcla de datos:

```
## Run config
run:
  name: my-lora-sft-run
  model_type: amazon.nova-2-lite-v1:0:256k
  model_name_or_path: nova-lite-2/prod
  data_s3_path: s3://my-bucket-name/train.jsonl # SageMaker HyperPod (SMHP) only and
not compatible with SageMaker Training jobs. Note replace my-bucket-name with your
real bucket name for SMHP job
  replicas: 4 # Number of compute instances for training, allowed
values are 4, 8, 16, 32
  output_s3_path: s3://my-bucket-name/outputs/ # Output artifact path
(Hyperpod job-specific; not compatible with standard SageMaker Training jobs). Note
replace my-bucket-name with your real bucket name for SMHP job

## MLFlow configs
mlflow_tracking_uri: "" # Required for MLFlow
mlflow_experiment_name: "my-lora-sft-experiment" # Optional for MLFlow. Note: leave
this field non-empty
mlflow_run_name: "my-lora-sft-run" # Optional for MLFlow. Note: leave this field non-
empty
```

```

training_config:
    max_steps: 100                # Maximum training steps. Minimal is 4.
    save_steps: 10 # This parameter suggests after how many training steps the
    checkpoints will be saved. Should be less than or equal to max_steps(please override
    this value with a numerical value equal or less than max_steps value; min: 4)
    save_top_k: 5                # Keep top K best checkpoints. Note supported only
    for SageMaker HyperPod jobs. Minimal is 1.
    max_length: 32768            # Sequence length (options: 8192, 16384, 32768
    [default], 65536)
    global_batch_size: 32        # Global batch size (options: 32, 64, 128)
    reasoning_enabled: true      # If data has reasoningContent, set to true;
    otherwise False

    lr_scheduler:
        warmup_steps: 15        # Learning rate warmup steps. Recommend 15% of
    max_steps
        min_lr: 1e-6            # Minimum learning rate, must be between 0.0 and 1.0

    optim_config:                # Optimizer settings
        lr: 1e-5                # Learning rate, must be between 0.0 and 1.0
        weight_decay: 0.0       # L2 regularization strength, must be between 0.0
    and 1.0
        adam_beta1: 0.9         # Exponential decay rate for first-moment estimates,
    must be between 0.0 and 1.0
        adam_beta2: 0.95        # Exponential decay rate for second-moment
    estimates, must be between 0.0 and 1.0

    peft:                        # Parameter-efficient fine-tuning (LoRA)
        peft_scheme: "lora"     # Enable LoRA for PEFT
        lora_tuning:
            alpha: 64            # Scaling factor for LoRA weights ( options: 32, 64,
    96, 128, 160, 192),
            lora_plus_lr_ratio: 64.0 # LoRA+ learning rate scaling factor (0.0-100.0)

```

Los parámetros más relevantes para LoRA son el ritmo de aprendizaje, el alfa (parámetro de escalado), el número de épocas que se debe entrenar y los pasos de preparación; en el caso del rango completo, los principales son el ritmo de aprendizaje, el número de épocas y los pasos de preparación. Las fórmulas se rellenan automáticamente con los valores predeterminados recomendados.

Configuración del bloque de mezcla de datos

Agregue la sección `data_mixing` a la fórmula con la distribución porcentual adecuada entre las categorías del conjunto de datos.

A continuación, describimos cada categoría de datos de Nova disponible.

Configuración de Nova 2.0 con la mezcla de datos

```
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

```

¿Qué significan estas categorías?

Categorías de datos de texto de Nova 2.0

Nombre de la categoría	Información
agentes	Datos de entrenamiento centrados en la toma de decisiones autónoma, la finalización de tareas y el comportamiento orientado a los objetivos en los sistemas de IA.
referencia	Datos lingüísticos fundamentales centrados en la comprensión general, la comunicación básica y las capacidades lingüísticas troncales.
chat	Intercambios conversacionales que muestran el flujo natural del diálogo, un contexto coherente a lo largo de todo el intercambio y las interacciones sociales apropiadas.
code	Código fuente de programación, documentación y debates técnicos que abarcan diversos lenguajes de programación y plataformas.
factuality	Información verificada y materiales de referencia centrados en la precisión, la validación de fuentes y la evaluación de la veracidad.
identidad	Marcos de personalidad y patrones de comportamiento centrados en rasgos de carácter, valores y estilos de interacción consistentes.

Nombre de la categoría	Información
long-context	Narrativas complejas y textos extensos centrados en mantener la coherencia y la relevancia en largos intercambios.
math	Contenido matemático que incluye libros de texto, problemas, soluciones y debates matemáticos.
rai	Casos y escenarios que enfatizan los principios de la IA ética, los aspectos que se deben tener en cuenta en materia de seguridad y la implementación responsable de la tecnología.
instruction-following	Ejemplos de pasos precisos para completar tareas en función de distintos niveles de peticiones e indicaciones del usuario.
raíz (semántica)	Contenido técnico sobre ciencia, tecnología, ingeniería y matemáticas, incluidos conceptos teóricos y de resolución de problemas.
planificación	Secuencias que demuestran el pensamiento estratégico, el desglose paso a paso de las tareas y la asignación eficiente de los recursos.
reasoning-chat	Escenarios de diálogo analítico centrados en el debate lógico y los flujos de conversación estructurados.
reasoning-code	Desafíos de programación y problemas algorítmicos centrados en el desarrollo sistemático de soluciones.
reasoning-factuality	Escenarios de evaluación de la información centrados en los procesos críticos de evaluación y verificación.

Nombre de la categoría	Información
reasoning-instruction-following	Análisis de tareas complejas centrado en la interpretación sistemática y la realización de tareas de forma metódica.
reasoning-math	Escenarios matemáticos de resolución de problemas centrados en la progresión lógica y las estrategias de solución.
reasoning-planning	Escenarios de toma de decisiones estratégicas centrados en un enfoque sistemático para el cumplimiento de objetivos.
reasoning-rag	Escenarios de recuperación y síntesis de información centrados en la comprensión contextual y la aplicación pertinente.
reasoning-rai	Escenarios de toma de decisiones éticas centrados en la evaluación sistemática de la seguridad y la equidad de la IA.
reasoning-stem	Escenarios científicos de resolución de problemas centrados en el análisis metódico y el desarrollo de soluciones.
rag	Ejemplos de cómo combinar eficazmente el conocimiento externo recuperado con las respuestas generadas para proporcionar información contextual precisa.
traducción	Combinaciones de contenido multilingüe que muestran una traducción precisa y, al mismo tiempo, conservan el contexto, el tono y los matices culturales.

Mezcla de datos multimodales (Nova 2.0)

```
data_mixing:
  dataset_catalog: sft_1p5_mm_chat      # Nova text dataset catalog
  sources:
    customer_data:
      percent: 50                        # Percent of overall mix to draw from customer data
    nova_data:                          # The remainder will be drawn from Nova data. The
categories below must add to 100
  charts: 1
  chat: 38
  code: 20
  docs: 3
  general: 2
  grounding: 1
  rag: 4
  screenshot: 4
  text: 8
  translation: 4
  video: 15
```

Nota: Nova 2.0 admite categorías de datos de video que no está disponible en Nova 1.0.

¿Qué significan estas categorías?

Categorías de datos multimodales de Nova 2.0

Nombre de la categoría	Información
gráficos	Representaciones visuales y descripciones de gráficos, gráficos circulares, gráficos de barras, diagramas de líneas y otras visualiza ciones estadísticas para ayudar al modelo a comprender y comunicar la información cuantitativa de manera eficaz.
chat	Datos conversacionales combinados con elementos visuales centrados en el diálogo contextual, la comprensión y las interacciones basadas en imágenes.

Nombre de la categoría	Información
code	Interfaces de programación y entornos de desarrollo centrados en la interpretación visual del código, capturas de pantalla del IDE y diagramas técnicos.
docs	Datos centrados en los documentos que combinan texto, imágenes, diseños y formatos para entrenar a los modelos con el objetivo de que comprendan y procesen varios tipos y estructuras de documentos a fin de facilitar conceptos como el reconocimiento del contenido de un PDF.
general	Contenido visual-textual diverso centrado en una amplia comprensión de las imágenes, los gráficos y el texto descriptivo adjunto.
grounding	Imágenes etiquetadas y materiales de referencia a visuales centrados en conectar los conceptos del lenguaje con las representaciones visuales del mundo real.
rag	Ejemplos de recuperación multimodal que muestran cómo combinar y referenciar eficazmente el conocimiento externo visual y textual para generar respuestas contextuales precisas.
screenshot	Capturas de la interfaz de la aplicación e imágenes de visualización digital centradas en la comprensión de las interfaces de software y las interacciones digitales.

Nombre de la categoría	Información
text	Un conjunto equilibrado de datos textuales contextuales creados a partir de las categorías del conjunto de datos de solo texto de Nova del SFT para enseñar habilidades generales.
traducción	Contenido visual multilingüe centrado en la interpretación multilingüe del texto en imágenes y elementos visuales culturales.
video	Contenido visual basado en el movimiento centrado en la comprensión temporal y la comprensión visual-narrativa secuencial.

¿Cómo lanzar un trabajo?

También puede consultar el archivo README si solo necesita obtener los detalles esenciales para iniciar la primera iteración con SFT.

Información sobre el contenedor

Información sobre el contenedor y comandos de lanzamiento

Modelo	Técnica	Subcategory	URI de imagen	Comando del lanzador de HyperPod
Nova 2.0	Microajuste	SFT (texto)	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

Modelo	Técnica	Subcategory	URI de imagen	Comando del lanzador de HyperPod
				<pre>_type": "ml.p5.48xlarge", "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-SFT-V2-latest" }</pre>

Modelo	Técnica	Subcategory	URI de imagen	Comando del lanzador de HyperPod
Nova 2.0	Microajuste	SFT (texto) + mezcla de datos	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_t_ext_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" }'

Modelo	Técnica	Subcategory	URI de imagen	Comando del lanzador de HyperPod
Nova 2.0	Microajuste	SFT (MM)	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 de imagen	Comando del lanzador de HyperPod
Nova 2.0	Microajuste	SFT (MM) + mezcla de datos	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" }'

Una vez que esté todo configurado, desde la raíz del repositorio sagemaker-hyperpod-cli, navegue hasta la carpeta de fórmulas de SFT predeterminadas de Nova.

- `cd /src/hyperpod_cli/sagemaker_hyperpod_recipes/recipes_collection/recipes/training/nova/`
- Aquí puede elegir si desea usar las fórmulas de Nova 1 o Nova 2 en función del modelo base elegido.

Para el SFT de Nova 2.0:

- Si quiere hacer un trabajo de SFT normal, debería poder ver una fórmula en esta carpeta:
 - `cd /src/hyperpod_cli/sagemaker_hyperpod_recipes/recipes_collection/recipes/fine-tuning/nova_2_0/nova_lite/SFT` y, a continuación, debería poder ver una fórmula en la carpeta `nova_lite_2_0_p5x8_gpu_sft.yaml`
- Si quiere hacer un trabajo de SFT con mezcla de datos, puede navegar a la carpeta de fórmulas de Forge para SFT:
 - `cd /src/hyperpod_cli/sagemaker_hyperpod_recipes/recipes_collection/recipes/fine-tuning/nova/forge/nova_2_0/nova_lite/SFT` y, a continuación, debería poder ver una fórmula en la carpeta `nova_lite_2_0_p5x8_gpu_sft_with_datamix.yaml`
- Edite las secciones de la fórmula requeridas por el trabajo, como `name`, `data_s3_path`, `validation_s3_path`, `output_s3_path` y `max_steps`. Como estamos realizando trabajos de SFT, la noción de épocas no se aplica aquí.

La configuración con mezcla de datos dará el mismo resultado, pero con una sección de mezcla de datos adicional en la parte inferior similar 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
```

Aquí hay dos categorías de datos de nivel superior:

- **nova_data**: esta es la mezcla de datos real y se subdivide en aún más categorías. Es imperativo que su suma dé como resultado 100 %.
- A continuación encontrará un desglose completo de estas categorías, incluido el recuento de tokens.
- **customer_data**: estos son los datos de entrenamiento, a los que se hace referencia en la clave `data_s3_path` situada en la parte superior del archivo YAML. El porcentaje que se proporciona aquí determina cuál será el porcentaje resultante para **nova_data**. Por ejemplo, en las selecciones porcentuales anteriores, durante el entrenamiento utilizaremos el 25 % de **customer_data** y el 75 % de **nova_data**, de los cuales el 15 % serán datos de **agents**, el 15 % serán datos de **business-and-finance**, el 15 % serán datos de **scientific**, el 15 % serán datos de **code** y el 15 % serán datos de **factual-and-news**.

Consejo: use `pip install -e` una vez más y ya tendrá todo listo para enviar el trabajo.

Vamos a sobrescribir un par de parámetros para utilizar la mezcla de datos:

```
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/  
'
```

El resultado debe contener un nombre de trabajo como el siguiente:

```
# 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/
}'
```

El resultado sería el siguiente:

```
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"
}
```

Puede ver el estado de su trabajo 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"
    }
  ]
}
```

o use directamente el comando `kubectl` para encontrarlos.

Por ejemplo:

```
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>

Consejo profesional: asegúrese de usar siempre el indicador `-o wide`, ya que el nodo de EKS que usa el trabajo le permitirá encontrar sus registros aún más rápido en la interfaz de usuario de AWS.

Cómo supervisar un trabajo

Puede ver los registros de tres maneras:

a) Usando CloudWatch

Los registros están disponibles en su cuenta de Amazon Web Services que contiene el clúster de HyperPod en CloudWatch. Para verlos en su navegador, vaya a la página de inicio de CloudWatch en su cuenta y busque el nombre del clúster. Por ejemplo, si su clúster se llamara `my-hyperpod-rig`, el grupo de registro tendría el prefijo:

- Grupo de registro: `/aws/sagemaker/Clusters/my-hyperpod-rig/{UUID}`
- Una vez en el grupo de registro, podrá encontrar el registro específico mediante el ID de la instancia del nodo, como `- hyperpod-i-00b3d8a1bf25714e4`.
 - `i-00b3d8a1bf25714e4` aquí representa el nombre de la máquina compatible con HyperPod en la que se está poniendo en marcha el trabajo de entrenamiento. Recuerde que en la salida del comando anterior `kubectl get pods -o wide -w -n kubeflow | (head -n1 ; grep my-cpt-run)` capturamos una columna llamada `NODE`.
 - En este caso, el nodo maestro se ponía en marcha en `hyperpod-i-00b3d8a1bf25714e4` y, por lo tanto, utilizaremos esa cadena para seleccionar el grupo de registro que queremos ver. Seleccione la que diga `SagemakerHyperPodTrainingJob/rig-group/[NODE]`

Los registros deberían tener un aspecto similar al siguiente:

b) Usando Información de CloudWatch

Si tiene a mano el nombre de su trabajo y no desea seguir todos los pasos anteriores, simplemente consulte todos los registros en `/aws/sagemaker/Clusters/my-hyperpod-rig/{UUID}` para encontrar el registro individual.

CPT

```
fields @timestamp, @message, @logStream, @log  
| filter @message like /(?!i)Starting CPT Job/  
| sort @timestamp desc  
| limit 100
```

Para completar el trabajo, sustituya Starting SFT Job por SFT Job completed.

Luego, puede hacer clic en los resultados y elegir el que diga “Epoch 0”, ya que ese será el nodo maestro.

C) Usando la AWS CLI

Puede optar por rastrear los registros mediante AWS CLI AWS CLI. Antes de hacerlo, compruebe su versión de AWS CLI utilizando `aws --version`. También se recomienda usar este script de utilidad que ayuda a rastrear los registros en tiempo real en su 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) Configuración de MLflow:

Puede hacer un seguimiento de las métricas a través de MLflow.

Creación de una aplicación MLflow

Uso de la interfaz de usuario de Studio: si crea un trabajo de entrenamiento a través de la interfaz de usuario de Studio, se crea automáticamente una aplicación MLflow predeterminada que se selecciona por defecto en Opciones avanzadas.

Uso de la CLI: si usa la CLI, debe crear una aplicación MLflow y pasarla como entrada a la solicitud de la API del trabajo de entrenamiento.

```
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)
```

Acceso a la aplicación MLflow

Uso de la CLI: cree una URL prefirmada para acceder a la interfaz de usuario de la aplicación MLflow:

```
aws sagemaker create-presigned-mlflow-app-url \
  --arn $mlflow_app_arn \
  --region $region \
  --output text
```

Cuando configure MLflow, puede pasar el URI de su fórmula o utilizar la función de sobrescritura al iniciar el trabajo. Puede encontrar un ejemplo práctico en el archivo README.

¿Cómo evaluar su modelo después del SFT?

Requisitos previos

- URI del punto de control de S3 del archivo manifest.json de su trabajo de entrenamiento (para modelos entrenados)
- Conjunto de datos de evaluación cargado en S3 en el formato correcto
- Ruta de S3 para ver los resultados de la evaluación

Pruebas comparativas listas para usar: utilice pruebas comparativas listas para usar para validar el rendimiento en tareas generales. Para obtener más información, consulte [aquí](#).

Uso de sus propios datos

También puede usar sus datos personalizados editándolos para que sigan el formato que se muestra más abajo y, luego, utilizando los contenedores mencionados a continuación para obtener los resultados de las inferencias junto con las probabilidades logarítmicas de las calibraciones, si es necesario.

Cree jsonl por tarea con la siguiente estructura:

```
{
  "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"
}
```

Los resultados generados durante la fase de inferencia del trabajo de evaluación tendrán la siguiente estructura:

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

Descripción de campos:

- prompt: entrada formateada enviada al modelo
- inference: respuesta generada por el modelo
- gold: respuesta correcta esperada del conjunto de datos de entrada, campo de respuesta de la entrada
- metadata: metadatos opcionales transferidos desde la entrada

Preparación de la configuración de evaluación

Comando para iniciar el trabajo de evaluación. Utilice “--override-parameters” para modificar cualquier entrada de la 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"
  }'
```

Lanzamiento del trabajo de evaluación

Comandos de lanzamiento de trabajos para diferentes fórmulas con las imágenes correspondientes.

Comandos de lanzamiento de trabajos de evaluación

Modelo	Técnica	Subcategory	URI de imagen	Comando
Nova 2.0	Evaluación	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":

Modelo	Técnica	Subcategory	URI de imagen	Comando
				"70897720 5387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-HP-Eval-latest" }

Lecciones aprendidas y consejos

- La calidad del conjunto de datos del SFT es fundamental. Debe hacer todo lo posible por filtrar los datos de baja calidad. Si tiene un subconjunto pequeño de datos de una calidad excepcional (tanto en términos de complejidad como de precisión), puede considerar la posibilidad de usarlo al final del entrenamiento para que el modelo converja mejor.
- Usamos los conjuntos de datos de texto y multimodales (MM) para la mezcla de datos. Nuestros experimentos con conjuntos de datos de texto demuestran que agregar la categoría exclusiva de Nova “reasoning-instruction-following” mejora significativamente el rendimiento en todas las pruebas comparativas genéricas. Le recomendamos incluir esta categoría en su estrategia de mezcla de datos si quiere controlar la posible regresión en pruebas comparativas generales después de someter los conjuntos de datos al SFT.
- En el caso de los conjuntos de datos de MM, nuestros experimentos indican que incorporar más del 20 % de las categorías de video a la mezcla es beneficioso para mantener un buen rendimiento en las pruebas comparativas genéricas.
- Además, el rendimiento de la combinación SFT + mezcla de datos se ve muy influido por el ritmo de aprendizaje, por lo que nuestro resultado sugiere refinar con el ritmo de aprendizaje predeterminado, es decir, $1e-5$ para LoRA y $5e-6$ para el rango completo.
- Por último, existe un equilibrio entre latencia y rendimiento si se combinan los conjuntos de datos patentados por Nova, por lo que nuestros resultados sugieren mezclar el 50 % como máximo para lograr un buen equilibrio.

Aprendizaje por refuerzo

Note

Recibirá la documentación detallada cuando se suscriba.

Nova Forge proporciona capacidades avanzadas de aprendizaje por refuerzo con la opción de utilizar funciones de recompensa remotas en su propio entorno. Los clientes pueden optar por integrar su propio punto de conexión para ejecutar la validación y obtener información real inmediata o, incluso, utilizar su propio orquestador para coordinar las evaluaciones de los agentes de varios turnos en su entorno.

Uso de su propio orquestador para las evaluaciones de los agentes de varios turnos

Para los usuarios de Forge que requieren conversaciones de varios turnos o funciones de recompensa que superen los tiempos de espera de 15 minutos, Nova Forge ofrece la función Uso de su propia orquestación (BYOO). Esto le permite coordinar las evaluaciones de los agentes de varios turnos en su entorno (por ejemplo, con herramientas químicas para puntuar los diseños moleculares o simulaciones robóticas que recompensan la ejecución eficiente de las tareas y penalizan las colisiones).

Temas

- [Información general de la arquitectura](#)
- [Configuración y ejecución](#)

Información general de la arquitectura

La arquitectura BYOO proporciona un control total sobre el proceso de implementación y generación a través de una infraestructura administrada por el cliente.

VPC de entrenamiento:

- **Despliegue:** coordina el entrenamiento al delegar la generación del despliegue en la infraestructura del cliente.
- **Entrenador:** actualiza el peso del modelo en función de los despliegues recibidos.

VPC del cliente (como ECS en EC2):

- Proxy de Lambda: recibe solicitudes de despliegue y se coordina con la infraestructura del cliente.
- Despliegue de respuestas de SQS: cola para devolver las implementaciones finalizadas a la infraestructura de entrenamiento.
- Generación de solicitudes de SQS: cola para solicitudes de la generación del modelo.
- Generación de respuestas de SQS: cola para respuestas de la generación del modelo.
- Contenedor del cliente: implementa una lógica de orquestación personalizada (se puede utilizar el kit de inicio proporcionado).
- DynamoDB: almacena y recupera el estado a lo largo del proceso de orquestación.

Flujo de trabajo:

1. El despliegue delega la generación de despliegues al Proxy de Lambda.
2. El Proxy de Lambda envía la solicitud de la API de despliegue a la Generación de solicitudes de SQS.
3. El contenedor del cliente procesa las solicitudes, administra las interacciones de varios turnos y llama a las funciones de recompensa.
4. El contenedor almacena y recupera el estado de DynamoDB según sea necesario.
5. El contenedor envía las respuestas del despliegue al Despliegue de respuestas de SQS.
6. El despliegue envía las implementaciones completas al entrenador para que actualice el peso.

Configuración y ejecución

Para obtener instrucciones de configuración detalladas, configuraciones de fórmulas, formatos de solicitud y respuesta y ejemplos de entornos, consulte la documentación confidencial proporcionada a los suscriptores de Nova Forge. Para obtener los documentos de Nova Forge, siga los pasos que se indican a continuación:

```
aws s3 cp s3://nova-forge-c7363-206080352451-us-east-1/v1/ ./ --recursive
```

Cuando haya descargado los activos, encontrará toda la documentación en la carpeta docs.

Kit de herramientas de IA responsable y moderación de contenido

Kit de herramientas de IA responsable

Nova Forge proporciona un kit de herramientas de IA responsable que incluye datos de entrenamiento y evaluación para adaptar los modelos con las directrices de IA responsable de Amazon Nova durante el proceso de entrenamiento, y controles de tiempo de ejecución para moderar las respuestas de los modelos durante la inferencia.

Datos de entrenamiento: los casos y escenarios que enfatizan los principios de la IA responsable, los aspectos que se deben tener en cuenta en materia de seguridad y la implementación responsable de la tecnología están disponibles para la mezcla de datos a fin de adaptar los modelos de forma responsable durante el entrenamiento previo continuo.

Evaluaciones: las evaluaciones que prueban la capacidad del modelo para detectar y rechazar contenido inapropiado, dañino o incorrecto están disponibles como una tarea comparativa para determinar la diferencia entre el rendimiento del modelo base y el rendimiento del modelo personalizado.

Controles de tiempo de ejecución: de forma predeterminada, el tiempo de ejecución de Amazon Nova controla las respuestas moderadas del modelo durante la inferencia. Para modificar estos controles de tiempo de ejecución, solicite la configuración de moderación de contenido personalizable de Amazon Nova. Para ello, contacte con un administrador de cuentas de AWS.

La seguridad es una responsabilidad compartida entre AWS y sus clientes. Cambiar el modelo base o utilizar el entrenamiento previo continuo para mejorar el rendimiento en un caso de uso específico puede repercutir en la seguridad, la imparcialidad y otras propiedades del nuevo modelo. Un método de adaptación sólido minimiza los cambios en la seguridad, la equidad y otras protecciones integradas en los modelos base, minimizando además el impacto en el rendimiento del modelo en tareas fuera del ámbito de personalización. Es necesario realizar pruebas integrales de las aplicaciones con conjuntos de datos representativos de los casos de uso para determinar si los resultados de las pruebas cumplen con las expectativas específicas de seguridad, equidad y demás propiedades, además de la eficacia global. Para obtener más información, consulte la Guía de uso responsable de la IA de Amazon Web Services, la Política de IA responsable de Amazon Web Services, la Política de uso aceptable de Amazon Web Services y los Términos de servicio de Amazon Web Services.

Uso responsable

Crear medidas de seguridad, protección y confianza con modelos de IA es una responsabilidad compartida entre AWS y nuestros clientes. Nuestro objetivo es alinear nuestros modelos con la [Política de uso aceptable de AWS](#) y mitigar los resultados no deseados mientras ofrecemos una experiencia satisfactoria al cliente. Nuestro enfoque respecto de la IA responsable (RAI) se estructura en torno a nuestras [dimensiones principales de la IA responsable](#), que se describen en la siguiente lista. Para cada una de estas dimensiones, desarrollamos directrices que rigen nuestra toma de decisiones a lo largo de todo el ciclo de vida del desarrollo del modelo. Este ciclo de vida abarca todas las etapas, desde la recopilación inicial de datos y el entrenamiento previo, hasta la implementación de las mitigaciones en tiempo de ejecución posteriores a la implementación.

- Equidad: tener en cuenta los impactos en las diferentes partes interesadas
- Explicabilidad: comprender y evaluar los resultados del sistema
- Privacidad y seguridad: obtener, usar y proteger los datos y los modelos de manera adecuada
- Seguridad: prevenir los resultados perjudiciales y el uso indebido
- Controlabilidad: contar con mecanismos para controlar y dirigir el comportamiento del sistema de IA
- Veracidad y solidez: lograr resultados correctos del sistema, incluso con entradas inesperadas o adversas
- Gobernanza: incorporar las prácticas recomendadas en la cadena de suministro de la IA, incluidos los proveedores y los implementadores
- Transparencia: permitir que las partes interesadas tomen decisiones informadas sobre su interacción con un sistema de IA

Directrices

Las directrices que utilizamos para dirigir el desarrollo de nuestro modelo incluyen, entre otras, la moderación del contenido que aliente, facilite o promueva lo siguiente:

- la participación en actividades peligrosas, autolesiones o uso de sustancias peligrosas,
- el uso, uso indebido o comercio de sustancias controladas, tabaco o alcohol,
- la violencia física o el gore,
- el abuso infantil o material de abuso sexual infantil,

- el maltrato o tráfico de animales,
- información errónea que posicione a personas o grupos como responsables de un engaño deliberado, de socavar la credibilidad de una institución ante el público en general o de poner en peligro la salud o los medios de vida de las personas,
- malware, contenido malicioso o cualquier contenido que facilite los delitos informáticos,
- falta de respeto, discriminación o estereotipo hacia una persona o un grupo,
- insultos, blasfemias, gestos obscenos, lenguaje sexualmente explícito, pornografía, símbolos de odio o grupos de odio,
- desnudez total que esté fuera de un contexto científico, educativo o de referencia,
- sesgo contra un grupo basado en una característica demográfica.

Recomendaciones

Idoneidad de uso: dado que los resultados de los modelos de IA son probabilísticos, Amazon Nova puede producir contenido inexacto o inapropiado. Los clientes deben evaluar los resultados para comprobar su precisión e idoneidad respecto de su caso práctico, especialmente si se expondrá directamente a los usuarios finales. Además, si Amazon Nova se utiliza en los flujos de trabajo de los clientes que toman decisiones consecuentes, los clientes deben evaluar los posibles riesgos de su caso de uso e implementar la supervisión humana adecuada, las pruebas y otras medidas de seguridad específicas para cada caso práctico para mitigar dichos riesgos.

Optimización de las peticiones: en caso de encontrarse con la moderación de Amazon Nova, considere la posibilidad de examinar las peticiones utilizadas con respecto a las directrices anteriores. Se recomienda optimizar las peticiones para reducir la probabilidad de generar resultados no deseados y producir los resultados esperados mediante los modelos de Amazon Nova. Preste atención a los casos en los que los usuarios controlan la entrada, incluido el contenido de píxeles, que podría afectar al rendimiento del modelo. Consulte la sección de directrices sobre peticiones de esta guía del usuario para obtener más información.

Privacidad: Amazon Nova está disponible en Amazon Bedrock. Amazon Bedrock es un servicio administrado y no almacena ni revisa las peticiones de los clientes ni las respuestas a peticiones de los clientes, y estas nunca se comparten entre clientes ni con los socios de Amazon Bedrock. AWS no utiliza entradas ni salidas generadas a través del servicio de Amazon Bedrock para entrenar modelos de Amazon Bedrock, incluido Amazon Nova. Consulte la sección [50.3](#) de las condiciones del servicio de AWS y las [preguntas frecuentes sobre la privacidad de los datos](#) de AWS para obtener más información. Para obtener información de privacidad específica del servicio, consulte

la sección Privacidad y seguridad de la documentación de [preguntas frecuentes sobre Amazon Bedrock](#). Amazon Nova toma medidas para evitar completar peticiones que puedan interpretarse como solicitudes de información privada. Si a un usuario le preocupa que su información privada se haya incluido en una respuesta de Amazon Nova, debe ponerse en contacto con nosotros [aquí](#).

Seguridad: todos los modelos de Amazon Bedrock, incluido Amazon Nova, cuentan con seguridad empresarial que permite a los clientes crear aplicaciones de IA generativa que cumplen con los estándares comunes de seguridad y cumplimiento de datos, incluidos el Reglamento General de Protección de Datos (RGPD) y la Ley de Portabilidad y Responsabilidad del Seguro de Salud (HIPAA). Los clientes pueden utilizar AWS PrivateLink para establecer una conectividad privada entre las redes personalizadas de Amazon Nova y las redes en las instalaciones sin exponer el tráfico de clientes a Internet. Los datos de los clientes siempre se cifran en tránsito y en reposo, y los clientes pueden usar sus propias claves para cifrar los datos, por ejemplo, mediante AWS Key Management Service. Los clientes pueden utilizar AWS Identity and Access Management para controlar de forma segura el acceso a los recursos de Amazon Bedrock, incluido Amazon Nova personalizado. Además, Amazon Bedrock ofrece capacidades integrales de control y registro que pueden respaldar los requisitos de auditoría y gobernanza de los clientes. Por ejemplo, Amazon CloudWatch puede ayudar a hacer un seguimiento de las métricas de uso necesarias para fines de auditoría, mientras que AWS CloudTrail puede ayudar a supervisar la actividad de las API y a solucionar problemas, ya que Amazon Nova se integra con otros sistemas de AWS. Los clientes también pueden elegir almacenar los metadatos, las peticiones y los resultados en su propio bucket cifrado de Amazon Simple Storage Service (Amazon S3).

Propiedad intelectual: AWS ofrece una cobertura ilimitada de indemnización por propiedad intelectual (PI) para los resultados de los modelos de Amazon Nova disponibles de forma general (consulte la Sección 50.10 de los [Términos del servicio](#)). Esto significa que los clientes están protegidos contra las reclamaciones de terceros que aleguen una infracción de PI o una apropiación indebida (incluidas las reclamaciones de derechos de autor) por parte de los resultados generados por estos modelos de Amazon Nova. Además, nuestra indemnización de PI estándar por el uso de los Servicios protege a los clientes de las reclamaciones de terceros que aleguen una infracción de la PI (incluidas las reclamaciones de derechos de autor) por parte de los Servicios (incluidos los modelos de Amazon Nova) y de los datos utilizados para entrenarlos.

Cuotas para Amazon Nova

Su Cuenta de AWS tiene cuotas predeterminadas —anteriormente conocidas como límites— para Amazon Bedrock. Para ver las cuotas de servicio de Amazon Bedrock, realice una de las siguientes acciones:

- Siga los pasos que se indican en [Viewing service quotas](#) y seleccione el servicio Amazon Bedrock.
- Consulte [Amazon Bedrock endpoints and quotas](#) en la Referencia general de AWS.

Note

Si una cuota está marcada como no ajustable a través de Service Quotas, puede enviar una solicitud a través del [formulario de aumento del límite](#) para que se considere la posibilidad de aumentarlo.

Para mantener el rendimiento del servicio y garantizar un uso adecuado de Amazon Bedrock, las cuotas predeterminadas asignadas a una cuenta pueden actualizarse en función de los factores regionales, el historial de pagos, el uso fraudulento o la aprobación de una solicitud de aumento de cuota.

Solicitud de un aumento de las cuotas de Amazon Nova

Para solicitar un aumento de todas las cuotas de su cuenta, siga los siguientes pasos:

- Si una cuota está marcada como Yes en la columna Adjustable en [Amazon Bedrock endpoints and quotas](#) en la Referencia general de AWS, puede ajustarla siguiendo los pasos que se indican en [Requesting a Quota Increase](#) en la Guía del usuario de Service Quotas <https://docs.aws.amazon.com/servicequotas/latest/userguide/>.
- Las cuotas de invocación del modelo bajo demanda en [Amazon Bedrock endpoints and quotas](#) en la Referencia general de AWS no se pueden ajustar mediante Service Quotas. Póngase en contacto con su administrador de Cuenta de AWS para que le considere para un aumento.

 Note

Debido a la abrumadora demanda, se dará prioridad a los clientes que generen tráfico que consuma la cuota que tienen asignada. La solicitud se denegará si no cumple esta condición.

- Puede enviar una solicitud a través del [formulario de aumento de límites](#) para que se le considere para un aumento, incluso si una cuota está marcada como No en la columna Adjustable de los [Amazon Bedrock endpoints and quotas](#) en la Referencia general de AWS.

Monitorización de Amazon Nova

La supervisión es una parte importante del mantenimiento de la fiabilidad, la disponibilidad y el rendimiento de Amazon Nova y de sus otras soluciones de AWS. AWS ofrece las siguientes herramientas de supervisión para controlar Amazon Nova, informar cuando algo salió mal y tomar medidas automáticas cuando sea necesario:

Dado que Amazon Nova está disponible a través de Amazon Bedrock, siga todas las instrucciones de monitorización que aparecen en [Monitorizar el estado y el rendimiento de Amazon Bedrock](#).

Seguridad en Amazon Nova

La seguridad en la nube en AWS es la máxima prioridad. Como cliente de AWS, se beneficiará de una arquitectura de red y de centros de datos diseñados para satisfacer los requisitos de seguridad de las organizaciones más exigentes.

La seguridad es una responsabilidad compartida entre AWS y usted. El [modelo de responsabilidad compartida](#) aborda tanto la seguridad de la nube como la seguridad en la nube:

- Seguridad de la nube: AWS es responsable de proteger la infraestructura que ejecuta servicios de AWS en la Nube de AWS. AWS también le proporciona servicios que puede utilizar de forma segura. Los auditores externos prueban y verifican periódicamente la eficacia de nuestra seguridad como parte de los [Programas de conformidad de AWS](#). Para obtener más información sobre los programas de conformidad que se aplican a Amazon Nova, consulte [Servicios de AWS en el ámbito del programa de conformidad](#).
- Seguridad en la nube: su responsabilidad viene determinada por el servicio de AWS que utilice. También es responsable de otros factores, como la confidencialidad de los datos, los requisitos de la empresa y la legislación y la normativa aplicables.

Dado que Amazon Nova está disponible a través de Amazon Bedrock, siga todas las instrucciones de seguridad en [Seguridad en Amazon Bedrock](#).

Creación de recursos de Amazon Nova con AWS CloudFormation

Al implementar modelos de Amazon Nova a través de Amazon Bedrock con CloudFormation, siga todas las pautas de CloudFormation en [Creación de recursos de Amazon Bedrock con CloudFormation](#).

Para obtener más información, como ejemplos de plantillas JSON y YAML para YOUR-RESOURCE-PLURAL, consulte [YOUR-SERVICE-RESOURCE-TOPNODE-IN-CLOUDFORMATION, se debe modificar el enlace en el archivo local-phrases.ent](#) en la Guía del usuario de AWS CloudFormation.

Obtención de más información sobre CloudFormation

Para conocer más información acerca de CloudFormation, consulte los siguientes recursos:

- [AWS CloudFormation](#)
- [AWS CloudFormation Guía del usuario de](#)
- [CloudFormation Referencia de la API de](#)
- [AWS CloudFormation Guía del usuario de la interfaz de la línea de comandos de](#)

Historial de documentación de la guía para desarrolladores de Amazon Nova

En la siguiente tabla, se describen las versiones de la documentación de Amazon Nova 2.0.

Cambio	Descripción	Fecha
Versión inicial de Amazon Nova 2.0	Versión inicial de la Guía para desarrolladores de Amazon Nova 2.0 con los nuevos modelos: Nova 2 Lite y Amazon Nova Sonic. En esta guía, se presentan las capacidades multimodales mejoradas, las características de razonamiento y el rendimiento mejorado en todos los niveles de modelos.	2 de diciembre de 2025

668