



Amazon Nova 2 개발자 안내서

Amazon Nova



Amazon Nova: Amazon Nova 2 개발자 안내서

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

Amazon의 상표 및 트레이드 드레스는 Amazon 외 제품 또는 서비스와 함께, Amazon 브랜드 이미지를 떨어뜨리거나 고객에게 혼동을 일으킬 수 있는 방식으로 사용할 수 없습니다. Amazon이 소유하지 않은 기타 모든 상표는 Amazon과 제휴 관계이거나 관련이 있거나 후원 관계와 관계없이 해당 소유자의 자산입니다.

Table of Contents

Amazon Nova 2란 무엇인가요?	1
주요 개념	1
Amazon Nova 모델	1
무엇을 빌드할 수 있나요?	2
이점	2
Amazon Nova 작동 방식	3
가격 책정	3
다음 단계	4
Amazon Nova 2의 새로운 기능	5
새 모델	5
새로운 특징 및 기능	5
Nova Multimodal Embeddings	5
확장된 사고 및 추론	5
기본 제공 도구	6
AI 에이전트 빌드	6
문서 이해 개선	6
비디오 이해 향상	6
모델 사용자 지정	6
Amazon Nova Forge	6
다음 단계	6
시작하기	8
콘솔에서 시작하기	8
텍스트 플레이그라운드 탐색	8
API 시작하기	9
프로그래밍 방식 액세스 권한을 부여하는 자격 증명 가져오기	11
사용자 또는 역할에 Amazon Bedrock 권한 연결	12
Amazon Nova 모델을 사용하여 텍스트 프롬프트에 대한 응답 생성	13
코어 추론	14
중요: 제한 시간 구성	15
코어 추론 주제	15
Converse API 사용	16
요청 구조	16
시스템 프롬프트 사용	17
추론 파라미터	17

추론 사용	18
Invoke API 사용	21
요청 구조	21
요청 파라미터	22
스트리밍 응답	22
ConverseStream을 사용하는 스트리밍	23
InvokeModelWithResponseStream을 사용하는 스트리밍	23
스트림 이벤트 유형	24
Amazon Nova 임베딩 사용	24
주요 기능	25
임베딩 생성	25
온디맨드 추론	29
이점	29
온디맨드 추론 사용	29
가격 책정	30
할당량 및 제한	30
Nova 기능 사용	31
추론	31
멀티모달 이해	32
모달별로 지원되는 콘텐츠 유형	32
이미지 이해	33
비디오 이해	35
문서 이해	37
음성-음성	40
주요 기능	40
시작하기	41
가져오기 및 구성 설명	41
SimpleNovaSonic 클래스 정의	42
클라이언트 초기화	42
이벤트 처리	43
세션 시작	43
오디오 입력 처리	46
세션 끝내기	47
응답 처리	48
오디오 재생	49
오디오 캡처	50

Main 함수 실행	51
코드 예제	53
시작하기 예제	53
고급 사용 사례	54
실습 워크숍	54
음성 대화 프롬프트	54
중요 지침	55
음성에 대해 권장되는 기준 시스템 프롬프트	55
음성 프롬프트 구성	55
시스템 프롬프트 구성	56
성별 표현 언어에 대한 성별 합의	57
음성에 대한 연쇄적 사고: 구조적 추론	58
제안된 문구의 과사용	59
핵심 개념	61
이벤트 수명 주기	61
이벤트 흐름 시퀀스	63
양방향 API를 사용하여 입력 이벤트 처리	63
양방향 API를 사용하여 출력 이벤트 처리	72
감청	78
턴 기반 제어 가능성	80
교차 모달 입력	81
언어 지원 및 다국어 기능	84
채팅 기록 관리	86
도구 구성	91
비동기식 도구 직접 호출	98
통합	101
Strands Agents	101
프레임워크 통합	104
Nova를 사용하는 고급 시스템	113
개요	113
확장된 사고	113
확장된 사고의 작동 방식	113
구성 옵션	116
지원되는 모델	117
도구 사용을 통한 확장된 사고	117
추론 토큰 및 요금 이해	117

FAQ	118
도구 사용	118
도구 사용 워크플로 이해	118
도구 생성	119
도구 직접 호출	122
기본 제공 시스템 도구	125
AI 에이전트 구축	128
에이전트 생성	128
에이전트 간접 호출	130
Web Grounding	133
Web Grounding 작동 방식	133
Web Grounding 사용 방법	133
리전별 가용성	134
응답 구조	134
그라운드링 안전	135
오류 처리	136
기본 제공 도구에 필요한 권한	136
프롬프트 엔지니어링	138
프롬프트 엔지니어링이란 무엇인가요?	138
프롬프트 엔지니어링 시작하기	138
모범 사례	139
역할 이해	139
정확한 프롬프트 생성	140
프롬프트의 섹션에 초점 맞추기	158
시스템 역할 사용	159
예제 제공(퓨샷 프롬프팅)	168
도구 직접 호출 시스템	178
고급 프롬프트 기법	179
멀티모달 입력 프롬프트	200
일반 멀티모달 지침	200
문서 및 이미지 이해	201
비디오 이해	35
코드 및 문제 해결	213
코드 라이브러리	213
Converse API 예제	213
InvokeModel API 예제	233

문제 해결	238
인증 및 설정	238
모델 액세스 거부됨	239
리전별 가용성 문제	239
제한 시간 구성	239
API 응답 문제	240
추론 모드 오류	241
도구 사용 문제	242
API 및 SDK 참조	246
요청 및 응답 스키마	246
전체 요청 구조	246
전체 응답 구조	251
SDK 참조	254
Amazon Nova 모델 사용자 지정	255
사용자 지정 접근 방식	255
사용자 지정 플랫폼	255
일반적인 사전 요구 사항	257
Amazon Nova 레시피	257
기본 레시피 가져오기	258
Forge 레시피 가져오기	259
사용 가능한 모델 및 알고리즘	259
Amazon Nova 2.0 Lite	260
SageMaker 훈련 작업에서	266
Amazon Nova 사용자 지정 모범 사례	266
Nova Forge SDK	270
학습	276
여러 반복에서 진행 상황 모니터링	311
평가	316
반복 학습	377
SageMaker HyperPod에서	377
Amazon Nova 2 모델의 컴퓨팅 요구 사항	378
Amazon Nova 사용자 지정 모범 사례	266
Nova Forge SDK	383
HP 클러스터 설정	383
필수 명령 가이드	384
Nova Forge 액세스 및 설정	394

학습	395
평가	434
MLflow 모니터링	480
반복 훈련	483
개요	483
작동 방식	484
반복 훈련을 사용해야 하는 경우	485
워크플로 예제: SFT → RFT	486
여러 반복에서 진행 상황 모니터링	488
모범 사례	490
비용 고려 사항	491
제한 사항	492
문제 해결	493
SageMaker 추론	494
특성	495
지원되는 모델 및 인스턴스	496
지원되는 AWS 리전	498
지원되는 컨테이너 이미지	498
모범 사례	498
지원	499
시작하기	499
API 참조	520
모델 평가	529
Amazon Nova Forge에서 침해 탐지	535
Amazon Bedrock 추론	536
사용자 지정 모델 온디맨드 추론용 배포	537
온디맨드 추론	542
제한 사항	543
Nova Forge	545
사전 조건	545
Nova Forge 구독	545
기타 사전 조건	546
Nova Forge 액세스 및 설정	546
Nova Forge 문서 가져오기	546
1단계: Nova Forge 구독	546
2단계: HyperPod 인프라 설정	552

콘텐츠 조정 설정	553
지속적인 사전 훈련 및 중간 훈련	553
중간 체크포인트란 무엇이며 왜 필요한가요?	553
어떤 체크포인트를 사용할 수 있나요?	554
사용할 체크포인트는 무엇인가요?	555
Nova 2.0에 대해 데이터 혼합을 사용하려면 어떻게 해야 하나요?	555
데이터 혼합 범주 분석	557
지도 미세 조정	561
소개	561
SFT는 언제 사용하나요?	561
언제 파라미터 효율적 미세 조정을 사용하고, 언제 전체 순위 SFT를 사용해야 하나요?	562
SFT에 대한 데이터 혼합	562
YAML 구성 예제	563
모델 체크포인트	565
훈련 접근 방식	566
시작하기 전 사전 조건	567
성공적인 SFT를 달성하기 위한 체계적인 접근 방식	567
실험 시퀀싱 및 데이터 혼합	568
SFT에 대한 데이터세트 준비	568
평가 지표	569
모범 사례	266
훈련 작업 구성 준비	571
데이터 혼합 블록 설정	572
작업을 시작하는 방법	578
작업을 모니터링하는 방법	585
SFT 이후 모델을 평가하려면 어떻게 해야 하나요?	588
학습한 교훈 및 팁	590
강화 학습	591
에이전트 멀티턴 평가를 위한 자체 오케스트레이터 가져오기	591
책임 있는 AI 도구 키트	592
책임 있는 AI 도구 키트	592
책임 있는 사용	594
지침	594
권장 사항	595
할당량	597
Amazon Nova 할당량 증가 요청	597

모니터링	598
보안	599
CloudFormation을 사용하여 리소스 생성	600
CloudFormation에 대해 자세히 알아보기	600
문서 이력	601

Amazon Nova 2란 무엇인가요?

Amazon Nova는 텍스트, 이미지, 비디오, 문서 및 음성을 처리하는 멀티모달 파운데이션 모델을 제공합니다. Amazon Nova 2 모델은 최대 1백만 개의 컨텍스트 토큰과 고급 추론 기능을 지원하므로 이를 토대로 복잡한 입력을 이해하고 정확한 응답을 생성하는 정교한 AI 애플리케이션을 빌드할 수 있습니다.

대화형 챗봇을 빌드하고, 문서와 비디오를 분석하며, 확장된 추론을 통해 AI 에이전트를 생성하고, 음성 지원 애플리케이션을 개발할 수 있습니다.

주요 개념

Amazon Nova 모델에 대해 알아보기 전에 다음과 같은 핵심 개념을 숙지하세요.

파운데이션 모델

API를 통해 액세스하는 여러 크기와 기능으로 사용 가능한 사전 훈련된 AI 시스템.

추론

모델에 요청을 전송하고 생성된 응답을 수신하는 프로세스.

추론

모델이 복잡한 문제를 분석하고 답변을 제공하기 전에 단계별 분석을 표시하도록 지원하는 확장된 사고 기능.

멀티모달

단일 요청에서 텍스트, 이미지, 비디오, 문서 등 여러 입력 유형을 함께 처리하고 이해하는 기능.

검색 증강 생성(RAG)

모델 응답을 자체 데이터 소스와 결합하여 컨텍스트에 기반한 보다 정확한 답변을 제공하는 기법.

Amazon Nova 모델

Amazon Nova 2에는 각각 여러 사용 사례에 최적화된 다음과 같은 모델이 포함되어 있습니다.

모델	입력 양식	출력 양식	사용 사례
Nova 2 Lite	텍스트, 이미지, 비디오, 문서	텍스트	속도와 비용 효율성을 우선하는 대용량 애플리케이션
Nova 2 Sonic	음성, 텍스트	음성, 텍스트	빠른 응답 시간의 음성 지원 애플리케이션
Nova Multimodal Embeddings	텍스트, 이미지, 문서, 비디오, 오디오	임베딩	시맨틱 검색, 추천 시스템 및 유사성 일치

모든 모델은 최대 1백만 개의 컨텍스트 토큰을 지원하며 단일 응답으로 최대 65,536개의 토큰을 생성할 수 있습니다. 추론 기능이 있는 모델은 확장된 사고를 수행하여 복잡한 문제를 단계별로 해결할 수 있습니다.

무엇을 빌드할 수 있나요?

다음은 Amazon Nova로 빌드할 수 있는 항목에 대한 예입니다.

- 지능형 문서 어시스턴트 - 최대 1백만 개의 컨텍스트 토큰으로 대규모 문서를 처리하여 질문에 답변하고 인사이트 추출(RAG 사용)
- 복잡한 추론 애플리케이션 - 모델의 단계별 분석(또는 추론)을 보여주는 확장된 사고로 여러 단계의 문제 해결
- 비디오 분석 파이프라인 - 대규모 비디오 콘텐츠에서 인사이트 추출, 요약 생성 및 주요 순간 식별 (Nova 2 Lite)
- 음성 지원 AI 에이전트 - 음성 입력을 이해하고 자연어로 응답하는 대화형 에이전트 빌드(Nova 2 Sonic)

이점

Amazon Nova는 다음과 같은 이점을 제공합니다.

멀티모달 이해

단일 요청에서 텍스트, 이미지, 비디오, 문서 및 음성을 처리합니다. Amazon Nova 모델은 여러 입력 유형 간 관계를 이해합니다.

확장된 컨텍스트

최대 1백만 개의 토큰을 지원하므로 컨텍스트 손실 없이 전체 코드 베이스, 긴 문서 또는 확장된 대화를 처리할 수 있습니다.

고급 추론

추론 기능이 있는 모델은 복잡한 문제를 분석하고 단계별 분석을 표시하여 여러 단계의 태스크에 대한 정확도를 개선합니다.

유연한 배포

인프라 없이도 Amazon Bedrock을 통해 모델에 액세스하여 미세 조정 및 강화 학습을 기반으로 모델을 관리하거나 사용자 지정합니다.

기본 제공 도구

웹 그라운드를 사용하여 실시간 정보 및 코드 인터프리터에 액세스하여 외부 통합 없이도 Python 코드를 실행합니다.

Amazon Nova 작동 방식

Amazon Nova 모델은 Amazon Bedrock을 통해 액세스하는 파운데이션 모델입니다. 기본 워크플로는 다음과 같습니다.

1. 애플리케이션은 입력 및 구성 파라미터를 사용하여 Amazon Bedrock에 요청을 보냅니다.
2. Amazon Nova 모델은 추론(구성된 경우)을 적용하여 입력을 처리합니다.
3. 이 모델은 응답을 생성하여 애플리케이션에 반환합니다.

RAG를 사용하여 데이터를 통합하거나 기본 제공 도구를 활성화하거나 미세 조정을 통해 모델을 사용자 지정하여 응답을 향상시킬 수 있습니다.

가격 책정

Amazon Nova 요금은 처리된 입력 및 출력 토큰에 기반합니다. 모델마다 요금 티어가 다릅니다.

- Nova 2 Lite - 비용 효율적인 대용량 처리에 최적화됨
- Nova 2 Sonic - 음성 지원 애플리케이션에서 균형 잡힌 요금 제공

현재 요금 정보는 [Amazon Bedrock 요금](#)을 참조하세요.

다음 단계

- Amazon Nova 2의 새로운 기능에 대한 자세한 내용은 [Amazon Nova 2의 새로운 기능](#) 섹션을 참조하세요.
- Amazon Nova 사용을 시작하려면 [Amazon Nova 2 시작하기](#) 섹션을 참조하세요.
- 핵심 추론 기능에 대한 자세한 내용은 [코어 추론](#) 섹션을 참조하세요.
- 사용 사례에 맞게 모델을 사용자 지정하려면 [SageMaker AI에서 Amazon Nova 모델 사용자 지정](#) 섹션을 참조하세요.

Amazon Nova 2의 새로운 기능

Amazon Nova 2는 이해, 크리에이티브 및 음성 기능 전반에 걸쳐 크게 향상되었습니다. 다음 섹션에서는 새로운 주요 특성 및 개선 사항을 설명합니다.

새 모델

Nova 2 Lite

확장된 사고 지원, 3단계 강도 제어 및 프로덕션 규모의 에이전트 워크플로에 최적화된 멀티모달 이해를 포함한 고급 추론을 제공하는 향상된 모델입니다.

Nova 2 Sonic

7개 언어로 향상된 음성 이해, 자연어 처리 및 음성 생성 기능을 갖춘 업그레이드된 대화형 음성 모델입니다.

Nova Multimodal Embeddings

텍스트, 이미지, 문서, 비디오 및 오디오 입력을 처리하고 임베딩을 생성하는 멀티모달 임베딩 모델입니다.

새로운 특징 및 기능

Nova Multimodal Embeddings

Nova Multimodal Embeddings는 단일 모델을 통해 텍스트, 문서, 이미지, 비디오 및 오디오를 지원하므로 교차 모달 검색 애플리케이션을 지원합니다. Nova Multimodal Embeddings에서는 이러한 각 콘텐츠 유형을 통합 시맨틱 공간에 매핑하므로 단일 모달, 교차 모달 및 멀티모달 벡터 작업을 수행하여 에이전트 검색 증강 생성(RAG) 및 멀티모달 시맨틱 검색과 같은 애플리케이션을 지원할 수 있습니다.

확장된 사고 및 추론

Nova 2 Lite는 확장된 사고를 지원하므로 응답을 생성하기 전에 모델이 복잡한 문제를 추론하는 데 더 많은 시간을 할애할 수 있습니다. 이 기능은 여러 도구를 사용하는 에이전트 워크플로, 고급 수학, 복잡한 계획 및 코드 생성을 비롯한 여러 단계의 추론 태스크에 대한 정확도를 개선합니다.

자세한 내용은 [Amazon Nova 2에서 확장된 사고](#) 섹션을 참조하세요.

기본 제공 도구

Amazon Nova 2에는 외부 통합 없이도 모델 기능을 확장하는 기본 제공 도구가 포함되어 있습니다.

- 웹 그라운드링 - 웹의 실시간 정보에 액세스하여 최신 응답을 제공하고 할루시네이션을 줄입니다.
- 코드 인터프리터 - Python 코드를 실행하여 계산을 수행합니다.

AI 에이전트 빌드

Amazon Nova 2 모델은 AI 에이전트를 빌드하는 데 최적화되어 있습니다. 이 모델을 사용하면 도구 사용을 개선하고 여러 단계의 태스크에 대한 추론을 개선하며 여러 복잡한 에이전트 워크플로에서 컨텍스트를 유지 관리하는 기능을 향상시킵니다.

문서 이해 개선

Nova 2 Lite는 복잡한 문서 레이아웃, 테이블, 차트 및 여러 페이지 문서를 더 잘 이해할 수 있는 향상된 문서 처리 기능을 제공합니다. 모델은 PDF, 스프레드시트 및 기타 문서 형식에서 정보를 더 정확하게 추출합니다.

비디오 이해 향상

Nova 2 Lite는 향상된 시각적 지각, 시간적 이해, 작업 인식, 더 높은 정확도로 더 긴 비디오 시퀀스를 처리하는 기능 등 향상된 비디오 분석 기능을 제공합니다.

모델 사용자 지정

Nova 2 Lite는 Amazon Bedrock 및 SageMaker AI에서 지도 미세 조정(SFT) 및 강화 미세 조정(RFT)을 지원하므로 특정 비즈니스 요구 사항에 맞게 Amazon Nova 2를 조정할 수 있습니다.

Amazon Nova Forge

Amazon Nova Forge는 Amazon Nova를 사용하여 프론티어 모델을 빌드하는 가장 쉽고 비용 효율적인 방법을 조직에 제공하는 최초의 서비스입니다.

다음 단계

- Amazon Nova 모델 및 기능에 대한 자세한 내용은 [Amazon Nova 2란 무엇인가요?](#) 섹션을 참조하세요.

- Amazon Nova 2.0 사용을 시작하려면 [Amazon Nova 2 시작하기](#) 섹션을 참조하세요.
- 핵심 추론 기능을 살펴보려면 [코어 추론](#) 섹션을 참조하세요.

Amazon Nova 2 시작하기

다음 방법을 통해 Amazon Nova 2 모델을 간접 호출할 수 있습니다.

- Amazon Bedrock [InvokeModel](#) 또는 [Converse](#) API 작업
- Nova 2 Lite, Nova 2 Sonic용 Amazon Bedrock [채팅 및 텍스트 플레이그라운드](#)

⚠ Important

AWS 또는 Amazon Bedrock을 처음 사용하는 경우 먼저 [Getting started with Amazon Bedrock](#)의 단계에 따라 Amazon Bedrock을 설정해야 합니다. 또는 [nova.amazon.com](#)에서 Amazon Bedrock을 입력하지 않고 Amazon Nova 모델을 사용해 보거나 [nova.amazon.com/dev](#)에서 무료로 빌드를 시작할 수 있습니다.

해당 방법으로 Amazon Nova 사용을 시작하려면 주제를 선택하세요.

Amazon Bedrock 콘솔에서 Amazon Nova 시작하기

이 섹션에서는 AWS 콘솔의 플레이그라운드를 사용하여 Amazon Nova 2 모델에 텍스트 프롬프트를 제출하고 텍스트 또는 이미지 응답을 생성하는 방법을 설명합니다. 다음 예제를 실행하기 전에 다음과 같은 사전 조건을 충족하는지 확인해야 합니다.

사전 조건

- AWS 계정이 있고 Amazon Bedrock에 필요한 권한을 가진 해당 계정의 역할에 대한 액세스 권한이 있습니다. 그렇지 않으면 [Getting started with Amazon Bedrock](#)의 단계를 따르세요.
- 미국 리전에서 모델에 액세스하는 경우 미국 CRIS 엔드포인트를 사용해야 합니다. 이 경우 모델 ID에 us 접두사(예: us.amazon.nova-2-lite-v1:0)를 추가합니다.
- 미국 이외 지역에서 모델에 액세스하는 경우 글로벌 CRIS 엔드포인트(예: global.amazon.nova-2-lite-v1:0)를 사용하거나 모델 ID에서 리전 접두사(예: us/eu/jp)를 추가할 수 있습니다.

텍스트 플레이그라운드 탐색

다음 예제는 텍스트 플레이그라운드를 사용하는 방법을 보여줍니다.

1. 그 다음 <https://console.aws.amazon.com/bedrock/>에서 Amazon Bedrock 콘솔을 엽니다.
2. 왼쪽 탐색 창의 플레이그라운드에서 채팅/텍스트를 선택합니다.
3. 모델 선택에서 모델 제공업체와 모델을 선택합니다. 이 예제에서는 Amazon을 선택한 다음 Amazon Nova 2 모델(예: Nova 2 Lite 또는 Nova 2 Sonic)을 선택합니다. 그런 다음, 적용을 선택합니다.
4. 텍스트 패널 아래에서 기본 프롬프트를 선택하거나 **Describe the purpose of a "hello world" program in one line**과 같은 프롬프트를 텍스트 패널에 입력합니다.
5. Amazon Nova의 이미지 이해 기능을 살펴보기 위해 컴퓨터에서 25MB 이하의 JPEG, PNG, GIF 또는 WEBP 형식의 이미지를 업로드할 수 있습니다. 이미지가 업로드된 후 Amazon Nova에 이미지에 대해 질문할 수 있습니다.
6. Amazon Nova의 문서 이해 기능을 살펴보기 위해 4.5MB 이하의 CSV, DOC, DOCX, HTML, MD, PDF, TXT, XLS 또는 XLSX 형식의 문서를 업로드할 수 있습니다. 문서가 업로드된 후 Amazon Nova에 문서에 대해 질문할 수 있습니다.
7. Amazon Nova의 비디오 이해 기능을 살펴보기 위해 컴퓨터에서 25MB 이하의 MKV, MOV 또는 MP4 형식의 비디오를 하나 업로드할 수 있습니다. 최대 1GB의 비디오에 Amazon S3를 사용할 수 있습니다. 비디오가 업로드된 후 Amazon Nova에 비디오에 대해 질문할 수 있습니다.
8. 실행을 선택하여 모델에서 추론을 실행합니다. 생성된 텍스트가 텍스트 패널의 프롬프트 아래에 표시됩니다.

API 시작하기

API를 시작하기 전에 AWS를 처음 이용하거나 AWS CLI 또는 AWS SDK를 설치해야 하는 경우 다음 절차를 따릅니다. 둘 다 적용되지 않는 경우 [프로그래밍 방식 액세스 권한을 부여하는 자격 증명 가져오기](#)로 이동합니다.

AWS를 처음 사용하는 경우

AWS 계정이 없는 경우 다음 절차에 따라 계정을 생성하세요. 또는 nova.amazon.com/dev에서 Amazon Nova를 사용하여 무료로 빌드를 시작할 수 있습니다.

AWS 계정에 가입하려면

1. <https://portal.aws.amazon.com/billing/signup>을 엽니다.
2. 온라인 지시 사항을 따르세요.

등록 절차 중 전화 또는 텍스트 메시지를 받고 전화 키패드로 확인 코드를 입력하는 과정이 있습니다.

AWS 계정에 가입하면 AWS 계정 루트 사용자가 생성됩니다. 루트 사용자에게는 계정의 모든 AWS 서비스 및 리소스에 액세스할 수 있는 권한이 있습니다. 보안 모범 사례는 사용자에게 관리 액세스 권한을 할당하고, 루트 사용자만 사용하여 [루트 사용자 액세스 권한이 필요한 작업](#)을 수행하는 것입니다.

가입 프로세스가 완료되면 AWS는 사용자에게 확인 이메일을 전송합니다. 언제든지 <https://aws.amazon.com/>으로 이동하고 내 계정을 선택하여 현재 계정 활동을 확인하고 계정을 관리할 수 있습니다.

AWS 계정 루트 사용자 보안을 유지합니다

1. 루트 사용자를 선택하고 AWS 계정 이메일 주소를 입력하여 [AWS Management Console](#)에 계정 소유자로 로그인하세요. 다음 페이지에서 비밀번호를 입력합니다.

루트 사용자를 사용하여 로그인하는 데 도움이 필요하면 AWS 로그인 사용 설명서의 [Signing in as the root user](#)을 참조하세요.

2. 루트 사용자의 다중 인증(MFA)을 활성화합니다.

지침은 IAM 사용 설명서의 [AWS 계정 루트 사용자용 가상 MFA 디바이스 활성화\(콘솔\)](#)를 참조하세요.

AWS 또는 AWS SDK를 설치해야 하는 경우

AWS CLI를 설치하려면 [최신 버전의 AWS CLI 설치 또는 업데이트](#)에 나와 있는 단계를 따르세요.

AWS SDK를 설치하려면 [AWS에서 빌드에 사용할 도구](#)에서 사용하려는 프로그래밍 언어에 해당하는 탭을 선택하세요.

다양한 프로그래밍 언어에 대해 AWS 소프트웨어 개발 키트(SDK)를 사용할 수 있습니다. 각 SDK는 개발자가 선호하는 언어로 애플리케이션을 쉽게 구축할 수 있도록 하는 API, 코드 예제 및 설명서를 제공합니다. SDK는 다음과 같은 유용한 작업을 자동으로 수행합니다.

- 서비스 요청에 대한 암호화 서명
- 요청 재시도
- 오류 응답 처리

프로그래밍 방식 액세스 권한을 부여하는 자격 증명 가져오기

사용자가 AWS Management Console 외부에서 AWS와 상호 작용하려면 프로그래밍 방식의 액세스 권한이 필요합니다. 프로그래밍 방식으로 액세스 권한을 부여하는 방법은 AWS에 액세스하는 사용자 유형에 따라 다릅니다.

사용자에게 프로그래밍 방식의 액세스 권한을 부여하려면 다음 옵션 중 하나를 선택합니다.

프로그래밍 방식 액세스가 필요한 위탁자는 누구인가요?	목적	방법
IAM 사용자	장기 자격 증명의 기간을 제한하여 AWS CLI, AWS SDK 또는 AWS API에 대한 프로그래밍 요청에 서명합니다.	사용하고자 하는 인터페이스에 대한 지침을 따릅니다. - AWS CLI의 경우 AWS Command Line Interface 사용 설명서의 IAM 사용자 자격 증명을 사용한 인증을 참조하세요. - AWS SDK와 도구는 AWS SDK 및 도구 참조 가이드에서 장기 자격 증명을 사용한 인증을 참조하세요. - AWS API는 IAM 사용자 안내서에서 IAM 사용자의 액세스 키 관리를 참조하세요.
IAM 역할	임시 자격 증명을 사용하여 AWS CLI, AWS SDK 또는 AWS API에 대한 프로그래밍 요청에 서명합니다.	IAM 사용자 안내서의 AWS 리소스와 함께 임시 자격 증명 사용 에 나와 있는 지침을 따릅니다.
IAM Identity Center에서 관리되는 사용자	임시 자격 증명을 사용하여 AWS CLI, AWS SDK 또는 AWS API에 대한 프로그래밍 요청에 서명합니다.	사용하고자 하는 인터페이스에 대한 지침을 따릅니다. AWS CLI의 경우 AWS Command Line Interface 사용 설명서의 IAM Identity Center를 사용하도록 AWS CLI 구성을 참조하세요.

프로그래밍 방식 액세스가 필요한 위탁자는 누구인 가요?	목적	방법
		AWS SDK, 도구, AWS API의 경우 AWS SDK 및 도구 참조 안내서의 IAM Identity Center authentication을 참조하세요.

사용자 또는 역할에 Amazon Bedrock 권한 연결

프로그래밍 방식 액세스를 위한 자격 증명을 설정한 후에는 사용자 또는 IAM 역할이 Amazon Bedrock 관련 작업에 액세스할 수 있도록 권한을 구성해야 합니다. 이러한 권한을 설정하려면 다음을 수행하세요.

1. AWS Management Console 홈페이지에서 IAM 서비스를 선택하거나 <https://console.aws.amazon.com/iam/>에서 IAM 콘솔로 이동하세요.
2. 사용자 또는 역할을 선택한 다음 사용자나 역할을 선택합니다.
3. 권한 탭에서 권한 추가, AWS 관리형 정책 추가를 차례로 선택합니다. [AmazonBedrockFullAccess](#) AWS 관리형 정책을 선택합니다.
4. 사용자 또는 역할이 모델을 구독하도록 허용하려면 인라인 정책 생성을 선택하고 JSON 편집기에서 다음 권한을 지정합니다.

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

```
}
```

Amazon Nova 모델을 사용하여 텍스트 프롬프트에 대한 응답 생성

모든 사전 조건을 충족한 후 [Converse](#) 요청으로 Amazon Nova 모델에 대한 모델 간접 호출 요청을 테스트할 수 있습니다.

AWS CLI를 설치하려면 [최신 버전의 AWS CLI 설치 또는 업데이트](#)에 나와 있는 단계를 따르세요. [프로그래밍 방식 액세스 권한을 부여하는 자격 증명 가져오기](#)의 단계에 따라 Boto3를 사용하도록 자격 증명을 설정했는지 확인합니다.

AWS CLI를 사용하여 Nova 2 Lite에서 텍스트 프롬프트에 대한 응답을 생성하려면 터미널에서 다음 명령을 실행합니다.

```
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"}}'
```

코어 추론

추론은 Amazon Nova 모델에 요청을 전송하고 생성된 응답을 수신하는 프로세스입니다. Amazon Nova 모델은 다음과 같은 두 가지 API 옵션을 통한 추론을 지원합니다.

- Converse API([Converse](#), [ConverseStream](#)): 여러 모델에서 일관된 인터페이스를 제공하므로 모델 사이를 전환하거나 여러 모델로 작동되는 애플리케이션을 더 쉽게 빌드할 수 있습니다. 대부분의 사용 사례에 권장됩니다.
- Invoke API([InvokeModel](#), [InvokeModelWithResponseStream](#)): 요청 페이로드는 각 모델의 네이티브 형식에 맞게 특별히 구성됩니다. 요청 본문에 제공된 프롬프트 및 추론 파라미터를 사용하여 추론을 실행합니다.

두 API는 모두 다음을 포함하여 동일한 핵심 기능을 지원합니다.

- 멀티턴 대화
- 멀티모달 입력(텍스트, 이미지, 비디오, 오디오)
- 도구 사용
- 가드레일
- 스트리밍 응답

요청 구조는 바이트 데이터(문서, 이미지, 비디오 및 오디오)가 인코딩되는 방식만 다르고 두 API 사이에서 거의 동일합니다. `reasoningConfig` 및 `TopK`와 같이 Amazon Nova 모델에 고유한 모델 요청 파라미터의 경우 이러한 파라미터는 `additionalModelRequestFields` 내 추가 `inferenceConfig` 객체 안에 배치됩니다. `InvokeModel` 및 `InvokeModelWithResponseStream`에 대한 최상위 파라미터입니다.

Note

코드 샘플 및 문제 해결에서 Nova 2 모델을 사용하는 코드 샘플 목록을 검토합니다.

Amazon Nova 모델을 사용하려면 `modelId`를 다음 중 하나로 설정합니다.

모델

모델 ID

Nova 2 Lite

• `global.amazon.nova-2-lite-v1:0`

모델	모델 ID
	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

중요: 제한 시간 구성

Important

Amazon Nova 추론 요청을 완료하는 데 최대 60분이 걸릴 수 있습니다. 클라이언트 제한 시간 설정을 적절히 구성합니다.

다음 예제는 Python 코드입니다. 사용자는 해당 SDK의 API 문서에서 원하는 SDK 언어 버전에 대한 설명서를 확인할 수 있습니다.

```
from botocore.config import Config

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

코어 추론 주제

이 섹션에서는 다음과 같은 주제를 다룹니다.

- Converse API 사용: 대부분의 Bedrock 모델에서 호환성을 제공하는 일관된 인터페이스
- Invoke API 사용: Nova 모델에 고유하며 다른 Bedrock 모델에 이식할 수 없는 인터페이스
- 응답 스트리밍: 실시간 응답 생성
- Amazon Nova 임베딩 사용: 텍스트 임베딩 기능

- 온디맨드 추론: 종량제 기반 추론 모델

Converse API 사용

Converse API는 Amazon Nova 모델과 상호 작용하기 위한 통합 인터페이스를 제공합니다. 모델별 세부 정보를 간략화하고 모든 Amazon Nova 모델에서 멀티턴 대화, 시스템 프롬프트 및 스트리밍 응답을 처리하기 위한 일관된 방법을 제공합니다.

주제

- [요청 구조](#)
- [시스템 프롬프트 사용](#)
- [추론 파라미터](#)
- [추론 사용](#)

요청 구조

- 멀티턴 대화: 여러 교환에서 컨텍스트 유지 관리
- 시스템 프롬프트: 페르소나 또는 응답 지침 등의 시스템 지침
- 문서 채팅: 문서 또는 문서 모음과 상호 작용 및 쿼리
- 비전: 이미지 및 비디오 처리 및 분석
- 도구 사용: 모델이 외부 도구 및 API를 사용하도록 지원
- 가드레일: 콘텐츠 필터링 및 안전 제어 적용
- 추론: 복잡한 문제 해결을 위한 확장된 사고

기본 Converse API 요청에는 모델 ID 및 메시지 목록이 포함됩니다.

```
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)

```

시스템 프롬프트 사용

시스템 프롬프트는 모델에 컨텍스트 및 지침을 제공합니다.

```

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)

```

추론 파라미터

추론 파라미터를 사용하여 모델 출력을 제어합니다. 다음은 사용 가능한 추론 파라미터입니다.

- `maxTokens`(정수): 생성할 최대 토큰 수(최대 65,000개)입니다. 지정하지 않으면 모델은 요청 컨텍스트를 기반으로 동적 기본값을 사용합니다.
- `temperature`(float): 무작위성을 제어합니다(0.0~1.0, 기본값 0.7). 값이 낮을수록 더 결정적인 출력이 생성됨
- `topP`(float): Nucleus 샘플링 임계치(0~1, 기본값 0.9)입니다. 값이 낮을수록 더 집중된 출력이 생성됨
- `stopSequences`(배열): 발생 시 생성을 중지하는 문자의 시퀀스

예제:

```
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)
```

추론 사용

Nova 2 Lite는 복잡한 문제 해결을 위해 확장된 사고를 지원합니다. `reasoningConfig`를 사용하여 추론을 활성화합니다.

기본적으로 추론은 단순한 쿼리에서 속도와 비용을 최적화하기 위해 비활성화됩니다. 이러한 간단한 태스크를 넘어서 작업이 필요한 경우 추론을 활성화할 수 있습니다. Nova 2에서는 세 가지 노력 수준을 통해 추론 깊이를 유연하게 제어할 수 있습니다.

낮은 수준의 노력(maxReasoningEffort: "low")

적합한 작업: 체계적인 사고가 요구되는 복잡성이 늘어난 태스크. 예를 들어 모델이 기존 코드 품질을 신중하게 고려해야 하는 코드 검토 및 개선 제안, 여러 요인을 신중하게 고려해야 하는 분석 태스크 또는 방법론적 접근 방식의 이점을 활용하는 문제 해결 시나리오에 사용할 수 있습니다. 낮은 수준의 노력은 심층적인 여러 단계의 계획을 세우지 않고도 기본적인 추론을 통해 정확도가 향상되는 복합 태스크에 적합합니다.

중간 노력(maxReasoningEffort: "medium")

적합한 작업: 여러 단계의 태스크 및 코딩 워크플로. 예를 들어 변경 사항을 구현하기 전에 모델이 기존 코드 구조를 이해해야 하는 소프트웨어 개발 및 디버깅, 여러 파일 또는 구성 요소에서 조정이 필요한 코드 생성, 상호 종속성이 존재하는 여러 단계의 계산이나 여러 제약 조건이 있는 태스크 계획에 사용할 수 있습니다. 중간 노력은 여러 도구를 조정하고 모델이 여러 순차적 작업에서 컨텍스트를 유지 관리해야 하는 에이전트 워크플로에 적합합니다.

높은 수준의 노력(maxReasoningEffort: "high")

적합한 작업: STEM 추론 및 고급 문제 해결. 예를 들어 엄격한 단계별 확인, 심층 조사를 요구하는 과학 분석 및 연구 태스크, 여러 차원에서 아키텍처 고려 사항이 포함된 복잡한 시스템 설계 또는 중요한 영향을 미치는 중요한 의사 결정 시나리오가 필요한 고급 수학적 문제 및 증명에 사용할 수 있습니다. 높은 수준의 노력은 정교한 추론, 대안에 대한 신중한 평가, 결론에 대한 철저한 검증이 필요한 태스크에서 최대의 정확도를 제공합니다.

다음 예제에서는 여러 추론 노력 수준을 보여줍니다.

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"
        }
    }
}
)

```

추론 파라미터:

다음은 추론 파라미터임

- type: enabled 또는 disabled(기본값: disabled)
- maxReasoningEffort: low, medium 또는 high. 추론이 활성화된 경우에 필수입니다.

Note

Temperature, topP, topK는 maxReasoningEffort를 high로 설정한 상태에서 사용할 수 없습니다. 이 경우 오류가 발생합니다.

응답에는 추론 콘텐츠가 포함됩니다.

```

{
  "output": {
    "message": {
      "role": "assistant",
      "content": [
        {
          "reasoningContent": {
            "reasoningText": {
              "text": "[REDACTED]"
            }
          }
        }
      ]
    }
  }
}

```

```

        }
    },
    {
        "text": "Based on the premises, we can conclude..."
    }
]
}
},
"stopReason": "end_turn"
}

```

Note

Amazon Nova 2에서 추론 콘텐츠는 [REDACTED]로 표시됩니다. 출력 품질 향상에 기여하므로 추론 토큰에 대한 요금은 계속 청구됩니다. 향후 릴리스에서 추론 콘텐츠를 노출하는 옵션을 유지하기 위해 이제 이 필드가 응답 구조에 포함됩니다. 모델 추론 프로세스를 설명하기 위한 최선의 접근 방식을 결정하기 위해 고객과 적극적으로 협력하고 있습니다.

Invoke API 사용

Invoke API는 요청 및 응답 형식을 제어하는 추가 기능과 함께 Amazon Nova 모델에 대한 직접 액세스 권한을 제공합니다. 모델별 세부 정보를 추상화하는 Converse API와 달리, Invoke API를 사용하면 모델의 기본 요청 및 응답 구조를 직접 작업할 수 있습니다.

Note

Invoke API는 Converse API에 특정한 문서 입력 양식을 제외하고 Converse API와 동일한 기능을 지원합니다.

요청 구조

Invoke API 요청에는 모델 ID 및 JSON 요청 본문이 필요합니다.

```

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"])

```

요청 파라미터

Invoke API는 다음과 같은 주요 파라미터를 지원합니다.

- **messages**: 역할 및 콘텐츠를 포함하는 대화 메시지 배열
- **system**: 컨텍스트 및 지침에 대한 선택적 시스템 프롬프트
- **inferenceConfig**: 모델 출력을 제어하는 파라미터(temperature, maxTokens, topP, topK, stopSequences, reasoningConfig)
- **toolConfig**: 함수 직접 호출을 위한 도구 사양 및 도구 선택

스트리밍 응답

스트리밍을 사용하면 모델 응답이 생성될 때 이를 점진적으로 수신하여 대화형 기능이 강화된 사용자 경험을 제공할 수 있습니다. Converse API 및 Invoke API 모두 스트리밍을 지원합니다.

ConverseStream을 사용하는 스트리밍

ConverseStream을 사용하여 응답을 이벤트 스트림으로 수신합니다.

```
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)
```

InvokeModelWithResponseStream을 사용하는 스트리밍

Invoke API로 스트리밍하는 경우 InvokeModelWithResponseStream을 사용합니다.

```
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)

```

스트림 이벤트 유형

스트리밍 응답에는 다음과 같이 여러 이벤트 유형이 포함됩니다.

- `messageStart`: 메시지의 시작을 나타냄
- `contentBlockStart`: 콘텐츠 블록의 시작을 나타냄
- `contentBlockDelta`: 증분 텍스트 또는 데이터를 포함함
- `contentBlockStop`: 콘텐츠 블록의 끝을 나타냄
- `messageStop`: 중지 이유를 포함하는 메시지의 끝을 나타냄
- `metadata`: 사용량 정보(토큰 수)를 포함함

Amazon Nova 임베딩 사용

Amazon Nova Multimodal Embeddings는 에이전트 RAG 및 시맨틱 검색 애플리케이션을 위한 멀티모달 임베딩 모델입니다. 단일 모델을 통해 텍스트, 문서, 이미지, 비디오 및 오디오를 지원하므로 교차 모달 검색을 지원합니다. Nova Multimodal Embeddings에서는 이러한 각 콘텐츠 유형을 통합 시맨틱 공간에 매핑하므로 단일 모달, 교차 모달 및 멀티모달 벡터 작업을 수행할 수 있습니다.

콘텐츠가 Nova Embeddings를 통해 전달되면 모델은 해당 콘텐츠를 벡터라고 하는 범용 숫자 형식으로 변환합니다. 벡터는 다양한 검색 기능에 사용할 수 있는 임의의 숫자 값 세트입니다. 유사한 콘텐츠에는 덜 유사한 콘텐츠보다 더 가까운 벡터가 부여됩니다.

애플리케이션:

- 시맨틱 콘텐츠 검색 및 추천: 콘텐츠에 대한 임베딩을 생성한 후 이를 사용하여 유사한 항목을 찾거나 개인화된 추천을 제공합니다.
- 멀티모달 검색: 여러 콘텐츠 유형의 임베딩을 결합하여 교차 모달 검색 기능을 구현합니다.

- RAG: 인터리브 텍스트 및 이미지가 있는 문서와 같은 멀티모달 콘텐츠에서 임베딩을 생성하여 GenAI 애플리케이션의 검색 워크플로를 지원합니다.

주요 기능

이러한 주요 기능은 Nova 임베딩을 차별화합니다.

- 통합 시맨틱 공간에서 텍스트, 이미지, 문서 이미지, 비디오 및 오디오 지원. 최대 컨텍스트 길이는 8K 토큰 또는 비디오 30초 및 오디오 30초입니다.
- 동기식 및 비동기식 API: API는 동기식 및 비동기식 사용을 모두 지원합니다.
- 대용량 파일 분할: 비동기 API는 사용자 정의 파라미터로 제어되는 긴 텍스트, 비디오 및 오디오에 대한 API 기반 분할을 제공하여 대용량 입력을 쉽게 처리할 수 있게 합니다. 이 모델은 각 세그먼트에 대해 단일 임베딩을 생성합니다.
- 오디오가 포함된 비디오: 오디오와 비디오를 동시에 처리합니다. 두 양식을 모두 나타내는 단일 임베딩을 원하는지 아니면 두 개의 개별 임베딩을 원하는지 지정할 수 있습니다.
- 임베딩 용도: 의도한 다운스트림 애플리케이션(검색/RAG, 분류, 클러스터링)에 따라 임베딩을 최적화합니다.
- 차원 크기: 임베딩 정확도와 벡터 스토리지 비용의 균형을 맞추기 위한 4가지 차원 크기: 3072, 1024, 384, 256.
- 입력 방법: S3 URI를 지정하거나 base64 인코딩으로 인라인 처리하여 임베딩할 콘텐츠를 전달합니다.

임베딩 생성

다음을 완료하여 임베딩을 생성합니다.

텍스트에 대한 동기식 임베딩:

```
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))
```

시도:

```
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))
```

비디오에 대한 비동기 임베딩:

```
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
            },
        },
    },
}
```

시도:

```
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'))
```

배치 추론

배치 추론을 사용하면 여러 요청을 제출하고 임베딩을 비동기적으로 생성할 수 있습니다. 배치 추론을 사용하면 단일 요청을 보내고 Amazon S3 버킷에서 응답을 생성하여 많은 수의 요청을 효율적으로 처리할 수 있습니다.

- 만든 파일에서 모델 입력을 정의한 후 파일을 S3 버킷에 업로드합니다.
- 그런 다음 배치 추론 요청을 제출하고 S3 버킷을 지정합니다.
- 작업이 완료되면 S3에서 출력 파일을 검색할 수 있습니다.
- 배치 추론을 사용하여 대규모 데이터 세트에 대한 모델 추론 성능을 개선할 수 있습니다.

배치 추론 데이터의 형식 지정 및 업로드

모델 간접 호출 작업을 제출할 때 선택하거나 지정할 S3 위치에 배치 추론 데이터를 추가해야 합니다. S3 위치에는 다음 항목이 있어야 합니다.

모델 입력을 정의하는 하나 이상의 JSONL 파일. JSONL에는 JSON 객체 행이 포함됩니다. JSONL 파일은 확장명 .jsonl로 끝나야 하며 다음 형식이어야 합니다.

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

```
}
```

지원되는 입력 파일 유형

- 이미지 형식: PNG, JPEG, WEBP, GIF
- 오디오 형식: MP3, WAV, OGG
- 비디오 형식: MP4, MOV, MKV, WEBM, FLV, MPEG, MPG, WMV, 3GP

온디맨드 추론

온디맨드 추론은 프로비저닝된 용량 없이 Amazon Nova 모델에 대한 서버리스 액세스 권한을 제공합니다. 이 모드는 사용량을 기반으로 워크로드 및 요금을 처리하도록 자동으로 조정됩니다.

이점

온디맨드 추론은 다음과 같은 몇 가지 이점을 제공합니다.

- 용량 계획 없음: 수요에 맞게 자동으로 규모 조정
- 종량제: 처리된 토큰에 대해서만 비용이 청구됨
- 즉시 가용성: 프로비저닝 또는 워밍업 시간이 필요하지 않음
- 비용 효율성: 가변적이거나 예측할 수 없는 워크로드에 적합

온디맨드 추론 사용

온디맨드 추론은 Amazon Nova 모델의 기본 모드입니다. API 직접 호출 시 모델 ID를 지정하기만 하면 됩니다.

```
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)
```

가격 책정

온디맨드 추론은 처리되는 입력 및 출력 토큰 수에 기반하여 요금이 청구됩니다. 현재 요금 세부 정보는 [Amazon Bedrock 요금](#)을 참조하세요.

할당량 및 제한

온디맨드 추론에는 모델 및 리전에 따라 달라지는 기본 할당량이 있습니다. 할당량 증가를 요청하려면 [Service Quotas 콘솔](#)을 사용하세요.

Amazon Nova 2 기능 사용

이 가이드에서는 빠르고 효과적으로 Nova의 기능을 애플리케이션에 통합하는 데 도움이 되는 태스크 기반 레시피와 실제 예제를 제공합니다. 그리고 다음을 원하는 개발자와 엔지니어를 위해 설계되었습니다.

- API를 통해 Nova 모델을 애플리케이션에 통합
- 사전 처리 요구 사항 및 최적화 전략 이해
- 멀티모달 이해 워크플로 구현

각 섹션에서는 다음을 제공합니다.

- 지원되는 형식, 크기 제한 및 토큰 추정에 대한 주요 기술 정보
- 직접 업로드와 Amazon S3 모두에서 API를 사용하는 방법을 보여주는 코드 예제
- 실제 애플리케이션을 보여주는 사용 사례
- 애플리케이션 설계 시 고려할 제한 사항

사전 조건

시작하기 전에 다음을 갖추었는지 확인하세요.

- Amazon Bedrock에 액세스할 수 있는 AWS 계정
- Bedrock 모델을 간접 호출하기 위한 적절한 IAM 권한
- AWS SDK 설치됨(Boto3 for Python 예제)
- Amazon S3와 같은 AWS 서비스에 대한 기본적인 지식(대규모 파일 처리용)

추론 기능

Amazon Nova 2 Lite는 확장된 사고(기본적으로 비활성화됨)를 지원합니다. 이 기능이 활성화되면 모델은 응답 품질을 개선하는 내부 추론 토큰을 생성합니다. Amazon Nova 2 Lite에서는 추론 콘텐츠가 출력에서 삭제되고 [REDACTED]로 표시되지만 이러한 토큰에 대한 요금은 여전히 부과됩니다.

향후 릴리스에서 이 콘텐츠를 노출하는 옵션을 유지하기 위해 추론 필드가 응답 구조에 포함됩니다. 확장된 사고에 대한 자세한 내용은 [the section called “확장된 사고”](#) 및 [the section called “코드 라이브러리”](#) 섹션을 참조하세요.

멀티모달 이해

Amazon Nova 2 Lite는 여러 입력 양식을 이해할 수 있습니다. 이 모델에는 이미지, 문서, 비디오 및 음성을 이해하고 분석하여 제공된 콘텐츠를 기반으로 질문을 추론하고 답변할 수 있는 비전 기능이 포함되어 있습니다.

이 섹션에서는 사용된 사전 처리 전략, 코드 예제 및 고려할 관련 제한 사항을 포함하여 Amazon Nova의 이미지, 문서 및 비디오 작업에 대한 지침을 간략하게 설명합니다.

모달별로 지원되는 콘텐츠 유형

다음 정보는 각 미디어 파일 유형에서 지원하는 파일 형식과 허용되는 입력 방법을 자세히 설명합니다.

미디어 파일 유형	지원되는 파일 형식	입력 방법	크기 제한 사항	객체 수
이미지	PNG, JPEG, GIF, WebP 참고: 애니메이션 GIF 또는 WebP 파일을 사용하는 경우 첫 번째 프레임만 사용됩니다.	요청에 데이터 임베딩	25MB	5
		Converse API를 사용하는 경우 데이터를 바이트로 인코딩합니다.		
		Invoke API를 사용하는 경우 데이터를 Base64 문자열로 인코딩합니다.		
비디오	MP4, MOV, MKV, WebM, FLV, MPEG, MPG, WMV, 3GP	Amazon S3 URI	총 2GB	1000
		요청에 데이터 임베딩	25MB	1
		Converse API를 사용하는 경우 데이터를 바이트로 인코딩합니다.		
		Invoke API를 사용하는 경우 데이터를 Base64 문자열로 인코딩합니다.		
		Amazon S3 URI	1GB	1

주제

- [이미지 이해](#)
- [비디오 이해](#)
- [문서 이해](#)

이미지 이해

이미지 이해란 이미지를 처리하고 다음과 같은 다양한 컴퓨터 비전 태스크를 수행하는 Amazon Nova의 기능을 말합니다.

- 객체 탐지 수행
- 시각적 질문 답변(VQA)을 통해 이미지에 대한 질문 답변
- 이미지 분류 및 요약
- 경계 상자 탐지 수행
- 광학 문자 인식(OCR)
- 객체 수 계산

이미지는 API에 바이트 배열로 전달되거나 S3 URI를 통해 전달되는 프롬프트로 포함될 수 있습니다.

주요 기술 정보

다음은 이 기능을 사용할 때 참고해야 할 주요 기술 정보입니다.

이미지 크기 조정 및 배율 조정

Amazon Nova는 이미지 배율을 자동으로 조정하여 품질과 성능을 최적화합니다.

- 가장 근접한 종횡비(예: 1:1, 1:2, 2:3 등)를 결정합니다.
- 한 면이 896픽셀 이상이거나 원본 이미지의 짧은 면 중 더 큰 쪽과 일치하도록 배율을 조정합니다.
- 종횡비 유지 관리
- 최대 8,000 × 8,000픽셀 해상도 지원

경계 상자 좌표:

- 스크린샷 또는 이미지 그라운드링에서 요소를 식별하는 등의 태스크에 유용합니다.

- 사후 처리에서 이미지의 원래 치수와 일치하도록 좌표 배율을 다시 조정할 수 있습니다.
- [0, 1,000] 배율로 경계 상자를 반환합니다.

이미지 토큰 추정

Amazon Nova는 처리를 위한 토큰으로 각 이미지를 변환합니다. 토큰 수는 이미지의 해상도와 종횡비에 따라 달라집니다.

다음은 이미지 해상도에 따른 대략적인 토큰 수의 예제입니다.

이미지 해상도	예상 토큰
900 x 450	515
900 x 900	~1,035
1400 x 900	~1,600
1800 x 900	~2,060
1,300 x 1,300	~2,155

이미지 이해 예제

요청에 이미지 데이터를 직접 임베드하는 방법에 대한 예제는 [코드 라이브러리](#)의 임베디드 자산을 사용하는 멀티모달 입력 - Converse API(비스트리밍) 예제를 참조하세요.

전체 페이로드가 25MB를 초과하는 대용량 이미지 파일 또는 여러 이미지 파일을 업로드하려면 Amazon S3를 사용합니다. 이미지 입력에 Amazon S3 URI 참조를 사용하는 방법에 대한 전체 예제는 [코드 라이브러리](#)의 S3 URI를 사용하는 멀티모달 입력 - Converse API(비스트리밍) 예제를 참조하세요.

Note

S3를 사용하는 경우 Amazon Bedrock 서비스에 버킷 및 객체에 액세스할 수 있는 권한이 있는지 확인합니다.

주요 제한 사항

다음 목록은 이미지 이해 모델의 현재 제한 사항을 간략하게 설명합니다.

- 다국어 이미지 이해: 모델은 다국어 이미지 및 비디오 프레임에 대한 이해도가 제한적이며, 단순한 태스크에서 어려움을 겪거나 할루시네이션이 발생할 수 있습니다.
- 사람 식별: Amazon Nova 2 모델은 이미지, 문서 또는 비디오에서 개인을 식별하거나 이름을 지정하는 기능을 지원하지 않습니다.
- 공간 추론: Amazon Nova 2 모델에서는 공간 추론 기능이 제한적입니다. 따라서 정밀한 현지화 또는 레이아웃 분석이 필요한 태스크에서 어려움을 겪을 수 있습니다.
- 이미지 및 비디오의 작은 텍스트: 이미지 또는 비디오의 텍스트가 너무 작은 경우 필요한 맥락을 유지하면서 관련 섹션으로 잘라내어 이미지의 텍스트 상대 크기를 늘리는 방법을 고려합니다.

비디오 이해

비디오 이해란 비디오 입력을 처리하고 다음과 같은 다양한 비디오 이해 태스크를 수행하는 Amazon Nova의 기능을 말합니다.

- 키 프레임 분석 및 비디오 콘텐츠 요약
- 비디오 세그먼트에 대한 질문 답변(비디오 질문 답변 또는 비디오 QA)
- 여러 프레임에서 객체 탐지 및 추적
- 동작, 장면 및 이벤트 식별
- 시간 분할을 수행하여 특정 순간 찾기
- 설명 캡션 생성 또는 비디오 시퀀스 요약

주요 기술 정보

다음은 이 기능을 사용할 때 참고해야 할 주요 기술 정보입니다.

비디오 크기 정보

Amazon Nova 비디오 이해 기능은 여러 가로 세로 비율을 지원합니다. 모든 비디오는 모델에 입력되기 전에 672*672 정사각형 치수로 입력에 따라 위 또는 아래로 왜곡을 적용하여 크기가 조정됩니다.

모델은 비디오 길이에 기반한 동적 샘플링 전략을 활용합니다. 길이가 16분 이하인 비디오의 경우 Amazon Nova 2 Lite는 초당 1개 프레임(FPS)을 샘플링합니다. 그러나 길이가 16분을 초과하는 비디오의 경우 샘플링되는 프레임 수를 일관되게 960개로 유지하기 위해 샘플링 속도가 감소하며 프레임

샘플링 속도도 이에 따라 달라집니다. 이 접근 방식은 긴 비디오 콘텐츠에 비해 짧은 비디오에 대해 보다 정확한 장면 수준의 비디오 이해를 제공하도록 설계되었습니다.

움직임이 적은 비디오는 1시간 이내로, 움직임이 많은 비디오는 16분 이내로 비디오 길이를 유지하는 것이 좋습니다.

4k 버전의 비디오와 Full HD 버전을 분석할 때 차이가 없어야 합니다. 마찬가지로 샘플링 속도는 1FPS 이므로 60FPS 비디오도 30FPS 비디오와 동일한 성능을 발휘해야 합니다. 필요한 것보다 높은 해상도와 FPS를 사용하는 것은 비디오 크기의 1GB 제한으로 인해 유용하지 않습니다. 이 경우 해당 크기 제한에 맞는 비디오 길이가 제한되므로 1GB보다 긴 비디오를 전처리해야 할 수 있습니다.

비디오 토큰

비디오 길이는 생성되는 토큰 수에 영향을 미치는 주요 요인입니다. 대략적인 비용을 계산하려면 예상 비디오 토큰 수에 사용 중인 특정 모델의 토큰당 가격을 곱합니다.

다음 표에는 Amazon Nova 2 Lite의 비디오 길이당 프레임 샘플링과 토큰 사용률에 대한 몇 가지 근사치가 나와 있습니다.

비디오 길이	샘플링할 프레임	샘플링 속도(fps)	토큰 근사치 계산
10초	10	1	2,880
30초	30	1	8,640
16분	960	1	276,480
20분	1200	1	345,600
30 분	1800	1	518,400
45분	2700	1	777,600

비디오 이해 예제

요청에 비디오 데이터를 직접 임베드하는 방법에 대한 예제는 [코드 라이브러리](#)의 임베이드 자산을 사용하는 멀티모달 입력 - Converse API(비스트리밍) 예제를 참조하세요.

비디오 입력에서 S3 URI 참조를 사용하는 방법에 대한 예제는 [코드 라이브러리](#)의 S3 URI를 사용하는 멀티모달 입력 - Converse API(비스트리밍) 예제를 참조하세요.

주요 제한 사항

다음은 모델 정확도와 성능이 보장되지 않을 수 있는 주요 모델 제한 사항입니다.

- 오디오 지원 없음: Amazon Nova 모델은 현재 시각적 프레임에만 의존하여 비디오 콘텐츠를 처리하고 이해하도록 훈련되어 있습니다. 비디오의 오디오 트랙은 처리되거나 분석되지 않습니다.
- 다국어 이미지 이해: Amazon Nova 모델에서는 다국어 이미지와 비디오 프레임에 대한 이해가 제한적입니다. 단순한 태스크에서 어려움을 겪거나 할루시네이션이 발생할 수 있습니다.
- 사람 식별: Amazon Nova 모델은 이미지, 문서 또는 비디오에서 개인을 식별하거나 이름을 지정하는 기능을 지원하지 않습니다. 모델은 시각적 콘텐츠에 있는 사람의 이름이나 ID를 제공하지 않습니다.
- 비디오의 작은 텍스트: 이미지 또는 비디오의 텍스트가 너무 작은 경우 비디오의 텍스트 상대 크기를 늘리는 방법을 고려합니다.
- 공간 추론: Amazon Nova 2 모델에서는 공간 추론 기능이 제한적입니다. 비디오에서 객체 위치, 거리 또는 공간 관계를 정확하게 이해해야 하는 태스크에서 어려움을 겪을 수 있습니다.
- 부적절한 콘텐츠: Amazon Nova 모델은 이용 정책을 위반하는 부적절하거나 노골적인 이미지는 처리하지 않습니다.
- 의료 애플리케이션: Amazon Nova 모델은 의료 이미지 또는 비디오에 대한 일반적인 분석을 제공할 수 있긴 해도, 이러한 아티팩트의 민감한 특성으로 인해 복잡한 진단 스캔과 같은 민감한 의료 이미지 해석에는 사용하지 않는 것이 좋습니다. Amazon Nova 모델의 응답은 전문적인 의학적 조언을 대체하는 것으로 간주해서는 안 됩니다.

문서 이해

Amazon Nova의 문서 이해 기능을 사용하면 프롬프트에 전체 문서(PDF, Word 파일, 스프레드시트 등)를 프롬프트의 일부로 포함할 수 있습니다. 이를 통해 모델은 문서 콘텐츠를 분석하거나 요약하거나 여가서 정보를 추출하거나 이에 관한 질문에 답변할 수 있습니다.

Amazon Nova 2 Lite는 이러한 문서 내 텍스트 및 시각적 요소(예: 차트 또는 테이블)를 모두 해석할 수 있습니다. 이를 통해 질문 답변, 요약, 긴 보고서 또는 스캔 문서 분석과 같은 사용 사례를 지원할 수 있습니다.

주요 문서 이해 기능으로, 긴 문서를 위한 초대형 컨텍스트 창(1M 토큰)과 단일 쿼리에서 여러 문서를 처리할 수 있는 기능이 포함됩니다.

지원되는 문서 양식 및 형식

Amazon Nova는 문서 입력을 두 가지 유형으로 구분합니다.

- 텍스트 기반 문서(예: TXT, CSV, HTML, 마크다운 또는 DOC) 파일은 주로 텍스트 콘텐츠에서 처리됩니다. Amazon Nova는 이러한 문서의 텍스트에서 정보를 이해하고 추출합니다.
- 미디어 기반 문서(예: PDF, DOCX 파일)에는 복잡한 레이아웃, 이미지, 차트 또는 임베디드 그래픽이 포함될 수 있습니다. 미디어 기반 문서의 경우 Amazon Nova는 비전 기반 이해를 활용하여 문서 텍스트와 함께 차트, 테이블, 다이어그램 또는 스크린샷과 같은 시각적 콘텐츠를 해석합니다.

지원되는 파일 형식에는 다음과 같은 일반적인 문서 유형이 포함됩니다.

- 일반 텍스트 및 구조화된 텍스트 파일: CSV, TXT
- 스프레드시트: XLS, XLSX, HTML, 마크다운
- 표준 이미지 형식(문서 내 이미지의 경우): PNG, JPG, GIF, WebP
- 문서 형식: DOC, DOCX, PDF
- CMYK 또는 SVG와 같은 이미지 인코딩이 포함된 PDF는 지원되지 않습니다.

문서 크기 제한 및 사용법 지침

제약 조건	Limit
최대 문서 수	요청당 최대 5개의 문서(직접 업로드와 Amazon S3 모두에 적용됨)
텍스트 기반 문서 크기	각 텍스트 문서는 4.5MB 이하여야 함
미디어 기반 문서 크기	PDF 및 DOCX 파일의 경우 개별 파일 크기 제한은 없습니다. 직접 업로드를 사용하는 경우 모든 미디어 문서의 결합된 크기는 25MB 이하여야 합니다. Amazon S3를 사용하는 경우 모든 미디어 문서의 결합된 크기는 2GB 이하여야 합니다.
지원되지 않는 PDF 콘텐츠	CMYK 색상 프로파일 또는 SVG 이미지가 포함된 PDF는 지원되지 않습니다.

가격 책정

Amazon Nova는 토큰 기반 요금을 사용합니다. 입력 토큰(첨부된 문서를 포함하여 전송하는 모든 항목) 및 출력 토큰(모델의 응답)에 대한 비용을 지불합니다.

PD에 대한 토큰 예측: 계획 시 표준 8.5x11인치 PDF 페이지의 경우 2,560개의 입력 토큰을 가정합니다(이 예측에서는 일반적인 페이지에서 텍스트 및 시각적 요소를 모두 포함함).

예제: API 및 S3를 통한 Nova의 문서 이해 사용

API를 통해 이를 사용하는 방법에 대한 예제는 [코드 라이브러리](#)의 임베디드 자산을 사용하는 멀티모달 입력 - Converse API(비스트리밍) 예제를 참조하세요.

S3를 통해 이를 사용하는 방법에 대한 예제는 [코드 라이브러리](#)의 S3 URI를 사용하는 멀티모달 입력 - Converse API(비스트리밍) 예제를 참조하세요.

음성-음성(Amazon Nova 2 Sonic)

Amazon Nova 2 Sonic은 음성 입력 및 출력을 통해 실시간 대화형 AI를 지원합니다. 다음 섹션에서는 대화형 음성 어시스턴트, 고객 서비스 자동화 및 대화형 애플리케이션을 빌드하기 위한 고급 기능을 설명합니다.

주요 기능

Amazon Nova 2 Sonic은 다음과 같은 기능을 제공합니다.

- 지연 시간이 짧은 실시간 멀티턴 대화를 지원하는 양방향 스트림 API를 사용하는 최첨단 스트리밍 음성 이해.
- 자동 언어 탐지 및 전환을 통한 다국어 지원. 표현력 있는 음성은 남성 음색과 여성 음색의 음성을 모두 포함하여 다음 언어로 제공됩니다.
 - 영어(미국, 영국, 인도, 호주)
 - 프랑스어
 - 이탈리아어
 - 독일어
 - 스페인 요리
 - 포르투갈어
 - 힌디어
- 사용자가 동일한 세션 내에서 언어를 전환할 때도 일관된 사용자 경험을 뒷받침하기 위해 지원되는 모든 언어를 말할 수 있는 다각형 음성.
- 실제 배포 시나리오에서 배경 소음에 대한 강건성.
- 지원되는 언어의 여러 액센트에 대한 견고한 지원.
- 지원되는 모든 언어에서 컨텍스트에 맞는 풍부한 정보가 제공되는 자연스럽고 사람과 같은 대화형 AI 경험.
- 입력된 스피치의 운율에 따라 동적으로 전달을 조정하는 적응형 스피치 응답
- 사용자가 말을 마치는 시점과 어시스턴트가 응답해야 하는 시점을 탐지하여 자연스러운 대화 리듬을 생성하는는 지능형 턴 기반 방식.
- 대화의 맥락을 잃지 않고 자연스럽게 사용자 중단 처리
- 검색 증강 생성(RAG)을 사용하여 엔터프라이즈 데이터로 지식 근거 마련
- 복잡한 AI 애플리케이션 구축을 위한 함수 직접 호출 및 에이전트 워크플로 지원

- 대화 흐름을 유지하면서 도구 직접 호출을 실행하는 비동기식 도구 처리로, 도구를 백그라운드에서 처리하는 동안 어시스턴트가 계속 말할 수 있습니다.
- 동일한 대화 내에서 오디오 입력과 텍스트 입력 모두에 대한 교차 모달 입력 지원을 제공하며, 이를 통해 유연한 상호 작용 패턴이 가능합니다.
- 연결 제한은 8분이며, 연결 갱신 및 세션 지속 패턴을 코드 샘플에서 사용할 수 있습니다.

음성-음성 시작

다음 섹션에서는 Amazon Nova 2 Sonic 모델을 사용하여 간단한 실시간 오디오 스트리밍 애플리케이션을 구현하는 방법을 단계별로 설명하는 예제를 제공합니다. 이 단순화된 버전은 Amazon Nova 2 Sonic 모델을 사용하여 오디오 대화를 생성하는 데 필요한 핵심 기능을 보여줍니다.

[Nova 샘플 GitHub 리포지토리](#)에서 다음 예제에 액세스할 수 있습니다.

연결 제한은 8분이며 [GitHub](#)에서 연결 갱신 및 대화 지속 패턴을 사용할 수 있습니다.

가져오기 및 구성 설명

이 섹션에서는 필요한 라이브러리를 가져오고 오디오 구성 파라미터를 설정합니다.

- `asyncio`: 비동기 프로그래밍용
- `base64`: 오디오 데이터 인코딩 및 디코딩용
- `pyaudio`: 오디오 캡처 및 재생용
- 스트리밍을 위한 Amazon Bedrock SDK 구성 요소
- 오디오 상수는 오디오 캡처 형식(16kHz 샘플 속도, 모노 채널)을 정의함

```
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
```

SimpleNovaSonic 클래스 정의

SimpleNovaSonic 클래스는 Amazon Nova Sonic 상호 작용을 처리하는 기본 클래스입니다.

- `model_id`: Amazon Nova Sonic 모델 ID(`amazon.nova-2-sonic-v1:0`)
- `region`: AWS 리전(기본값: `us-east-1`)
- 프롬프트 및 콘텐츠 추적을 위한 고유 ID
- 오디오 재생을 위한 비동기 대기열

```
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
```

클라이언트 초기화

이 메서드는 다음으로 Amazon Bedrock 클라이언트를 구성합니다.

- 지정된 리전에 적합한 엔드포인트
- AWS 자격 증명에 환경 변수를 사용한 인증 정보
- AWS API 직접 호출을 위한 SigV4 인증 체계

```
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)
```

이벤트 처리

이 어시스턴트 메서드는 Amazon Nova Sonic 모델과의 모든 통신에 사용되는 양방향 스트림으로 JSON 이벤트를 전송합니다.

```
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)
```

세션 시작

이 메서드는 세션을 시작하고 오디오 스트리밍을 시작하도록 나머지 이벤트를 설정합니다. 이러한 이벤트는 동일한 순서로 전송해야 합니다.

```
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())

```

오디오 입력 처리

다음 메서드는 오디오 입력 수명 주기를 처리합니다.

- `start_audio_input`: 오디오 입력 스트림을 구성하고 시작합니다.
- `send_audio_chunk`: 오디오 청크를 인코딩하고 모델로 전송합니다.
- `end_audio_input`: 오디오 입력 스트림을 올바르게 닫습니다.

```

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)

```

세션 끝내기

이 메서드는 다음을 수행하여 세션을 올바르게 닫습니다.

- promptEnd 이벤트 전송
- sessionEnd 이벤트 전송
- 입력 스트림 닫기

```

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()

```

응답 처리

이 메서드는 모델의 응답을 지속적으로 처리하고 다음을 수행합니다.

- 스트림의 출력을 기다립니다.
- JSON 응답을 구문 분석합니다.
- 자동 음성 인식과 트랜스크립션으로 콘솔에 인쇄하여 텍스트 출력을 처리합니다.
- 디코딩하고 재생을 위해 대기열에 추가하여 오디오 출력을 처리합니다.

```

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}")

```

오디오 재생

이 방법은 다음 태스크를 수행합니다.

- PyAudio 입력 스트림 초기화
- 대기열에서 지속적으로 오디오 데이터 검색
- 스피커를 통해 오디오를 재생합니다.
- 완료되면 리소스를 적절하게 정리합니다.

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

시도:

```
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()
```

오디오 캡처

이 방법은 다음 태스크를 수행합니다.

- PyAudio 출력 스트림 초기화
- 오디오 입력 세션 시작
- 마이크에서 지속적으로 오디오 청크 캡처
- Amazon Nova Sonic 모델로 각 청크 전송
- 완료 시 적절하게 리소스 정리

```

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()

```

시도:

```

        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()

```

Main 함수 실행

Main 함수는 다음을 수행하여 전체 프로세스를 오케스트레이션합니다.

- Amazon Nova 2 Sonic 클라이언트 생성
- 세션 시작
- 오디오 재생 및 캡처를 위한 동시 태스크 생성
- 사용자가 **Enter** 키를 눌러 중지할 때까지 대기

- 올바르게 세션 끝내기 및 태스크 정리

```
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())
```

코드 예제

다음 코드 예제는 Amazon Nova 2 Sonic을 빠르게 시작하는 데 도움이 됩니다. [Amazon Nova Sonic GitHub 샘플](#) 페이지에서 전체 예제 목록에 액세스할 수 있습니다.

시작하기 예제

Amazon Nova 2 Sonic 사용을 시작하기 위한 간단한 예제는 다음 구현을 참조하세요.

- [기본 Amazon Nova 2 Sonic 구현\(Python\)](#): 양방향 스트리밍 API에서 이벤트가 어떻게 구조화되는지 보여주는 기본 구현입니다. 이 버전은 개입 기능(어시스턴트가 말하는 동안 중단)을 지원하지 않으며 진정한 양방향 커뮤니케이션을 구현하지 않습니다.
- [모든 기능을 갖춘 Amazon Nova 2 Sonic 구현\(Python\)](#): 실제 양방향 커뮤니케이션과 개입을 지원하는 모든 기능을 갖춘 구현입니다. 이를 통해 사용자가 어시스턴트의 말을 중단하는 등 실제 사람과 대화하는 것처럼 자연스러운 대화가 가능합니다.
- [도구 사용이 포함된 Amazon Nova 2 Sonic\(Python\)](#): 도구 사용 예제를 통해 양방향 통신 기능을 확장하는 고급 구현입니다. 이 버전은 Amazon Nova 2 Sonic이 외부 도구 및 API와 상호 작용하여 향상된 기능을 제공하는 방법을 보여줍니다.
- [텍스트 및 혼합 입력이 포함된 Amazon Nova 2 Sonic\(Python\)](#): Amazon Nova 2 Sonic이 텍스트를 입력으로 지원하는 방법을 보여주는 구현 예제입니다.
- [Java WebSocket 구현\(Java\)](#): 이 예제에서는 Java를 사용하여 실시간 음성-음성 대화를 위해 Amazon Nova 2 Sonic과 통합되는 양방향 WebSocket 기반 오디오 스트리밍 애플리케이션을 구현합니다.
- [NodeJS Websocket 구현\(NodeJS\)](#): 이 예제에서는 NodeJS를 사용하여 실시간 음성-음성 대화를 위해 Amazon Nova 2 Sonic과 통합되는 양방향 WebSocket 기반 오디오 스트리밍 애플리케이션을 구현합니다.
- [NodeJS Websocket 구현\(C#\)](#): 이 예제에서는 .NET을 사용하여 실시간 음성-음성 대화를 위해 Amazon Nova 2 Sonic과 통합되는 양방향 WebSocket 기반 오디오 스트리밍 애플리케이션을 구현합니다.

고급 사용 사례

더 복잡한 사용 사례를 보여주는 고급 예제는 다음 구현을 참조하세요.

- [Amazon Bedrock Knowledge Base 구현\(NodeJS\)](#): 이 예제에서는 NodeJS를 사용하여 Amazon Nova 2 Sonic을 Amazon Bedrock 지식 베이스와 통합해서 지능형 대화형 애플리케이션을 구축하는 방법을 보여줍니다.
- [채팅 기록 관리\(Python\)](#): 이 예제에는 Python을 사용하여 사용자와 Amazon Nova 2 Sonic 간의 모든 상호 작용을 캡처하고 보존하는 채팅 기록 로깅 시스템이 포함되어 있습니다.
- [호텔 예약 취소\(NodeJS\)](#): 이 예제에서는 NodeJS를 사용하여 호텔 예약 취소 시스템을 구현하는 Amazon Nova 2 Sonic의 실제 고객 서비스 사용 사례를 보여줍니다.
- [LangChain Knowledge Base 통합\(Python\)](#): 이 구현은 Python을 사용하여 향상된 대화 경험을 위해 Amazon Nova 2 Sonic의 음성-음성 기능을 LangChain 기반 지식 베이스와 통합하는 방법을 보여줍니다.
- [대화 재개\(NodeJS\)](#): 이 예제에서는 Amazon Nova 2 Sonic을 사용하여 대화 재개 기능을 구현하는 방법을 보여줍니다. 이 애플리케이션은 호텔 예약 취소 시나리오를 컨텍스트로 사용하여 세션 전체에서 대화 상태를 유지하는 방법을 보여줌으로써 사용자가 NodeJS를 사용하여 이전에 중단된 상호 작용을 원활하게 계속할 수 있도록 합니다.
- [Nova 2 Sonic Speaks First\(NodeJS\)](#): 이 예제에서는 Amazon Nova 2 Sonic이 대화를 사전에 시작하는 방법을 보여줍니다.
- [세션 연속\(Python\)](#): 이 예제에서는 원활한 세션 전환을 구현하여 Amazon Nova 2 Sonic으로 무제한 대화 길이를 활성화하는 방법을 보여줍니다. 애플리케이션은 백그라운드에서 새 세션을 자동으로 생성하고 해당 세션으로 전환하므로 중단이나 컨텍스트 손실 없이 대화를 무제한으로 계속할 수 있습니다.

실습 워크숍

양방향 스트리밍 인터페이스와 함께 Amazon Nova 2 Sonic을 사용하여 음성 채팅 애플리케이션을 구축하는 과정을 안내하는 실습 워크숍을 사용할 수 있습니다. [워크숍에 액세스](#)하고 [전체 코드 예제](#)를 확인할 수 있습니다.

음성 대화 프롬프트

Nova 2는 힌디어의 음성별 트랜스크립션 형식 지정을 제어하도록 설계된 특수 프롬프트 기능인 음성 프롬프트를 도입했습니다. 음성 프롬프트는 시스템 프롬프트와 함께 작동하지만 다음과 같은 고유한 목적을 지원합니다.

- 시스템 프롬프트: 어시스턴트의 동작, 성격 및 응답 스타일 제어
- 음성 프롬프트: 힌디어 코드 스위칭(라틴 문자/데바나가리 문자/혼합 스크립트)을 위한 트랜스크립션 형식 지정 제어

중요 지침

음성 프롬프트는 미리 구성되어 있으며 문서화된 대로 정확하게 사용해야 합니다. 특정 트랜스크립션 형식 지정 요구 사항에 맞게 설계되었으며, 변경 사항으로 인해 예기치 않은 동작이 발생할 수 있으므로 수정하거나 사용자 지정해서는 안 됩니다.

음성 프롬프트를 사용하는 경우:

- 힌디어 코드 스위칭(라틴 문자/데바나가리 문자/혼합)에 대한 스크립트 출력을 제어해야 함

음성 프롬프트를 사용하지 않는 경우:

- 일반 지침 또는 어시스턴트 동작의 경우(대신 시스템 프롬프트 사용)
- 힌디어 트랜스크립션 형식을 사용하지 않는 경우
- 특정 형식 지정 요구 사항이 사용 사례에 적용되지 않는 경우

모범 사례: 특히 힌디어 트랜스크립션 형식이 필요한 경우 음성 프롬프트만 포함합니다. 언어 기본 설정, 응답 스타일, 세부 수준 및 추론을 비롯한 다른 모든 지침은 시스템 프롬프트에 들어gå야 합니다.

중요: 음성 프롬프트는 시스템 프롬프트 이후에 모델로 전송되어야 합니다.

음성에 대해 권장되는 기준 시스템 프롬프트

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.

음성 프롬프트 구성

코드 스위칭

참고: 이 기능은 현재 힌디어에만 적용됩니다.

원하는 출력 스크립트에 기반하여 다음 프롬프트 중 하나를 선택합니다.

라틴 문자 스크립트 출력(라틴 문자를 사용하는 힌디어)의 경우:

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

데바나가리 문자 스크립트 출력의 경우:

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

혼합 스크립트 출력(자연 코드 스위칭)의 경우:

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

시스템 프롬프트 구성

응답 세부 수준 제어

간결한 대화식 응답:

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.

상세하고 철저한 응답:

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.

언어 미러링

Nova는 사용자가 말하는 언어를 인식하고 이에 응답할 수 있습니다. 이 프롬프트를 사용하여 언어 일관성을 유지 관리합니다.

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.

성별 표현 언어에 대한 성별 합의

일부 언어에는 어시스턴트가 자신을 설명할 때 동사, 형용사 또는 대명사에서 성별 합의가 필요합니다. 이러한 언어의 경우 선택한 음성과 일치하도록 시스템 프롬프트에서 어시스턴트의 성별을 지정합니다.

해당되는 언어: 힌디어, 포르투갈어, 프랑스어, 이탈리아어, 스페인어, 러시아어, 폴란드어

성별 합의가 중요한 경우:

- 힌디어: 항상 필요 - 화자의 1인칭 성별을 기반으로 동사 활용
- 포르투갈어/프랑스어: 과거 분사 또는 형용사를 사용할 때 필요(예: 'I am tired' - 'Estou cansada/cansado')
- 이탈리아어/스페인어: 형용사를 사용하여 자신을 설명할 때 필요(예: 'I am happy' - 'Sono contenta/contento')

구현:

음성 선택에 따라 시스템 프롬프트 시작 위치에 적절한 성별 식별자를 포함합니다.

여성스러운 음성(Kiara, Carolina, Ambre, Beatrice, Lupe, Tiffany)의 경우:

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

남성스러운 음성(Arjun, Leo, Florian, Lorenzo, Carlos, Matthew)의 경우:

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

예:

여성스러운 음성의 힌디어(Kiara):

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

결과: मैं अच्छी हूँ (main achchhi hoon) 및 मैं अच्छा हूँ (main achchha hoon) 비교

남성스러운 음성의 이탈리아어(Lorenzo):

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

결과: 'Sono contento' 및 'Sono contenta' 비교

음성에 대한 연쇄적 사고: 구조적 추론

모델에서 복잡한 문제에 대한 추론을 표시하려는 경우 이 프롬프트를 사용합니다.

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.

참고: 모델이 모든 요청에 대한 추론을 진행하지 않도록 하려면 프롬프트에 몇 가지 장면 예제를 추가할 수 있습니다(아래 예제 참조).

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)

제안된 문구의 과사용

Nova Sonic 2는 Sonic 1보다 문구 제안에 더 민감합니다. 이러한 증가된 민감도는 본질적으로 좋거나 나쁨을 의미하지 않으며, 사용 사례에 따라 달라집니다. 일관되고 예측 가능한 문구 표현을 원하는 경우 유용할 수 있습니다. 그러나 보다 자연스러운 변형을 원하는 경우 명시적 문구 목록을 사용하면 과사용으로 이어질 수 있습니다.

명시적인 문구 목록과 함께 프롬프트를 포함하는 경우 모델은 다음과 같이 이를 매우 자주 사용합니다.

예제 1 - 강조 문구:

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."

예제 2 - 대화 필터:

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.

권장 사항:

- 일관된 문구 표현을 원하는 경우: 명시적 문구 목록은 Sonic 2에서 예측 가능한 온브랜드 응답을 생성하는 데 적합합니다.
- 자연스러운 변형을 원하는 경우: 명시적 문구 목록을 제공하지 마세요. 대신 '자연스러운 대화 음성'과 같은 일반적인 지침을 사용하거나 원샷 예제를 제공합니다.

더 나은 접근 방식 - 원샷 예제 사용:

문구를 나열하는 대신 원하는 어조와 스타일을 보여주는 1~2개의 예제를 제공합니다.

자연스럽고 유용한 어조

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.

간결하고 직접적인 어조

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.

공감력 있는 전문가 어조

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?

기술적이지만 이해하기 쉬운 어조

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.


이 접근 방식은 반복적인 문구 패턴을 트리거하지 않고 여전히 어조와 스타일에 대한 제어를 유지하면서 모델에 원하는 동작을 보여줍니다.

핵심 개념

Amazon Nova 2 Sonic은 실시간 대화형 AI에 대한 구조화된 이벤트와 함께 양방향 스트리밍 아키텍처를 사용합니다. 이러한 핵심 개념의 이해는 효과적인 음성 애플리케이션을 구축하는 데 필수적입니다.

이벤트 수명 주기

다음 다이어그램에서는 전체 양방향 스트리밍 이벤트 수명 주기를 보여줍니다.



양방향 스트리밍 이벤트 수명 주기는 세션 초기화부터 대화 완료까지 구조화된 패턴을 따릅니다. 각 대화에는 자연스러운 음성 상호 작용을 생성하기 위해 함께 작동하는 애플리케이션의 입력 이벤트 및 Amazon Nova 2 Sonic의 출력 이벤트가 포함되어 있습니다.

이벤트 흐름 시퀀스

일반적인 대화는 다음과 같은 이벤트 시퀀스를 따릅니다.

1. 세션 시작 - 대화 세션 초기화
2. 시스템 프롬프트 - 시스템 지침 전송
3. 채팅 기록(선택 사항) - 대화 컨텍스트 제공
4. 오디오 청크 - 사용자 오디오 입력 스트리밍
5. 완료 시작 - AI에서 처리 시작
6. ASR 트랜스크립트(사용자) - 사용자 음성 트랜스크립션
7. 도구 사용(선택 사항) - AI에서 도구 실행 요청
8. 도구 처리(선택 사항) - 도구 결과 처리 및 반환
9. 트랜스크립트(어시스턴트) - SPECULATIVE - 예비 AI 응답
10. 오디오 청크 - AI 오디오 출력 스트리밍
11. 트랜스크립트(어시스턴트) - FINAL - 최종 AI 응답 트랜스크립트
12. 콘텐츠 종료 오디오 - 오디오 콘텐츠의 끝 표시
13. 프롬프트 종료 - 프롬프트 처리 완료 표시
14. 세션 종료 - 대화 종료

양방향 API를 사용하여 입력 이벤트 처리

양방향 스트림 API는 구조화된 입력 및 출력 이벤트를 갖춘 이벤트 기반 아키텍처를 사용합니다. 성공적인 대화형 애플리케이션을 구현하고 상호 작용 전반에 걸쳐 적절한 대화 상태를 유지하려면 올바른 이벤트 순서를 이해하는 것이 중요합니다.

개요

Nova Sonic 대화는 구조화된 이벤트 시퀀스를 따릅니다. 먼저 온도 및 토큰 제한과 같은 추론 구성 파라미터가 포함된 `sessionStart` 이벤트를 전송합니다. 다음으로 `promptStart`를 전송하여 오디오 출력 형식 및 도구 구성을 정의하고, 모든 후속 이벤트에 포함되어야 하는 고유한 `promptName` 식별자를 할당합니다.

각 상호 작용 유형(시스템 프롬프트, 오디오 등)에 대해 세 부분으로 된 패턴을 따릅니다. `contentStart`를 사용하여 콘텐츠 유형과 콘텐츠 역할(SYSTEM, USER, ASSISTANT, TOOL, SYSTEM_SPEECH)을 정의한 다음, 실제 콘텐츠 이벤트를 제공하고, `contentEnd`로 마무리하여 해당 세그먼트를 닫습니다. `contentStart` 이벤트는 도구 결과, 스트리밍 오디오 또는 시스템 프롬프트 중 무엇을 전송할지 지정합니다. `contentStart` 이벤트에는 고유한 `contentName` 식별자가 포함됩니다.

대화 기록

시스템 프롬프트 후 오디오 스트리밍이 시작되기 전에 한 번만 대화 기록을 포함할 수 있습니다. 대화 기록은 동일한 `contentStart/textInput/contentEnd` 패턴을 따릅니다. 각 기록 메시지의 `contentStart` 이벤트에 USER 및 ASSISTANT 역할을 정의해야 합니다. 이는 현재 대화에 대한 필수적인 컨텍스트를 제공하지만, 새로운 사용자 입력이 시작되기 전에 완료되어야 합니다.

오디오 스트리밍

오디오 스트리밍은 연속 마이크 샘플링으로 작동합니다. 초기 `contentStart`를 전송한 후, 오디오 프레임(각각 약 32ms)이 마이크에서 직접 캡처되어 동일한 `contentName`을 사용하여 즉시 `audioInput` 이벤트로 전송됩니다. 이러한 오디오 샘플은 캡처되는 대로 실시간으로 스트리밍되어 대화 전체에서 자연스러운 마이크 샘플링 케이던스를 유지해야 합니다. 모든 오디오 프레임은 대화가 끝나고 명시적으로 닫힐 때까지 하나의 콘텐츠 컨테이너를 공유합니다.


세션 닫기

대화가 끝나거나 종료되어야 하는 경우 열려 있는 모든 스트림을 올바르게 닫고 올바른 순서로 세션을 끝내는 것이 중요합니다. 세션을 올바르게 끝내고 리소스 누수를 방지하려면 다음과 같은 특정 닫기 순서를 따라야 합니다.

- `contentEnd` 이벤트를 사용하여 열려 있는 모든 오디오 스트림을 닫습니다.
- 원래 `promptName`을 참조하는 `promptEnd` 이벤트를 전송합니다.
- `sessionEnd` 이벤트를 전송합니다.

이러한 닫기 이벤트를 건너뛰면 대화가 불완전하거나 리소스가 분리될 수 있습니다.

이러한 식별자는 계층 구조를 생성합니다. `promptName`은 모든 대화 이벤트를 연결하고, 각 `contentName`은 특정 콘텐츠 블록의 경계를 표시합니다. 이 계층 구조는 모델이 상호 작용 전반에 걸쳐 적절한 컨텍스트를 유지하도록 합니다.



입력 이벤트 흐름

이 섹션에서는 입력 이벤트 흐름의 구조를 설명합니다.

1. RequestStartEvent(세션 시작)

세션 시작 이벤트는 추론 구성으로 대화를 초기화하고 탐지 설정을 컵니다.

추론 구성:

- maxTokens: 응답에서 생성할 최대 토큰 수
- topP: 무작위성 제어를 위한 Nucleus 샘플링 파라미터(0.0~1.0)
- temperature: 생성 시 무작위성 제어(0.0~1.0)

턴 탐지 구성: endpointingSensitivity 파라미터는 사용자가 발언을 마쳤을 때 Nova Sonic에서 이를 탐지하는 속도를 제어합니다.

- HIGH: 일시 중지를 빠르게 탐지하여 응답 속도를 높이지만 느린 화자를 중단시킬 수 있음
- MEDIUM: 대부분의 대화형 시나리오에 대한 균형 잡힌 민감도(기본값 권장)
- LOW: 음성 끝을 탐지하기 전에 더 오래 기다림, 사려 깊거나 주저하는 화자에게 적합함

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

예시:

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

2. PromptStartEvent

프롬프트 시작 이벤트는 출력 형식, 음성 선택 및 사용 가능한 도구를 포함한 대화 구성을 정의합니다.

사용 가능한 음성 ID 목록은 [언어 지원 및 다국어 기능](#)을 참조하세요.

```
{
  "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

텍스트

텍스트 콘텐츠 시작 이벤트는 시스템 프롬프트, 대화 기록 및 교차 모달 텍스트 입력에 대해 사용됩니다.

대화형 파라미터:

- **true:** 활성 음성 세션 중에 텍스트 메시지를 허용하는 교차 모달 입력 활성화

- **false**: 시스템 프롬프트 및 대화 기록에 대한 표준 텍스트 입력

역할 유형:

- **SYSTEM**: 시스템 지침 및 프롬프트
- **USER**: 대화 기록 또는 교차 모달 입력에서 사용자 메시지
- **ASSISTANT**: 대화 기록에서 어시스턴트 응답
- **SYSTEM_SPEECH**: 힌디어 코드 스위칭(라틴 문자/데바나가리 문자/혼합 스크립트)을 위한 트랜스크립션 형식 지정 제어

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

예제 - 시스템 프롬프트:

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

```
}
```

예제 - 교차 모달 입력:

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

오디오

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

도구

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

4. TextInputContent

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

5. AudioInputContent

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



```
}
}
```

6. ToolResultContentEvent

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

7. InputContentEndEvent

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

8. PromptEndEvent

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

9. RequestEndEvent

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

양방향 API를 사용하여 출력 이벤트 처리

Amazon Nova Sonic 모델이 응답하면 구조화된 이벤트 시퀀스를 따릅니다. 이 흐름은 `sessionId`, `promptName`, `completionId`와 같은 고유 식별자를 포함하는 `completionStart` 이벤트로 시작합니다. 이러한 식별자는 응답 주기 전체에서 일관되며 모든 후속 응답 이벤트를 통합합니다.

개요

각 응답 유형은 일관된 세 부분으로 된 패턴을 따릅니다. `contentStart`는 콘텐츠 유형 및 형식, 실제 콘텐츠 이벤트를 정의하고, `contentEnd`는 해당 세그먼트를 닫습니다. 응답에는 일반적으로 자동 음성 인식(ASR) 트랜스크립션(사용자가 말한 내용), 선택적 도구 사용(외부 정보가 필요한 경우), 텍스트 응답(모델이 말하려는 내용), 오디오 응답(음성 출력) 등 여러 콘텐츠 블록이 순차적으로 포함됩니다.

응답 콘텐츠 유형

ASR 트랜스크립션

ASR 트랜스크립션이 먼저 표시되어 `contentStart`에 `role: "USER"` 및 `"additionalModelFields": "{\\"generationStage\\":\\"FINAL\\"}"`을 사용하여 모델이 사용자 음성을 이해한 내용을 전달합니다.

도구 사용

모델에 외부 데이터가 필요한 경우 특정 도구 이름과 파라미터를 포함하는 도구 관련 이벤트를 전송합니다.

텍스트 응답

텍스트 응답은 `role: "ASSISTANT"` 및 `"additionalModelFields": "{\\"generationStage\\":\\"SPECULATIVE\\"}"`를 사용하여 계획된 음성의 미리 보기를 제공합니다.

오디오 응답

그런 다음 오디오 응답은 스트림 전체에서 동일한 `contentId`를 공유하는 base64로 인코딩된 음성 청크를 전달합니다.

개입 지원

오디오 생성 중 Amazon Nova Sonic은 개입 기능을 통해 자연스러운 대화 흐름을 지원합니다. Amazon Nova Sonic이 말하는 동안 사용자가 Nova Sonic을 중단하면 Nova Sonic은 즉시 음성 생성을 중지하고 듣기 모드로 전환한 다음, 중단 발생을 알리는 콘텐츠 알림을 전송합니다. Nova Sonic은 실제

간보다 빠르게 작동하기 때문에 일부 오디오는 이미 전송되었지만 아직 재생되지 않았을 수 있습니다. 중단 알림을 통해 클라이언트 애플리케이션은 오디오 대기열을 지우고 즉시 재생을 중지하여 응답성이 뛰어난 대화 경험을 제공할 수 있습니다.

최종 트랜스크립션

오디오 생성이 완료되거나 개입을 통해 중단된 후 Amazon Nova Sonic은 실제로 말한 내용의 문장 수준 트랜스크립션이 포함된 추가 텍스트 응답을 제공합니다. 이 텍스트 응답에는 `role: "ASSISTANT"` 및 `"additionalModelFields": "{\\"generationStage\\":\\"FINAL\\"}"`이 있는 `contentStart` 이벤트가 포함됩니다.


사용량 추적

응답 처리 과정에서 토큰 소비를 추적하기 위해 `usageEvent` 이벤트가 전송됩니다. 이러한 이벤트에는 입력 토큰과 출력 토큰(음성 및 텍스트 모두)에 대한 자세한 지표와 그 누적 합계가 포함되어 있습니다. 각 `usageEvent`는 대화 흐름의 다른 이벤트와 동일한 `sessionId`, `promptName`, `completionId`를 유지합니다. 세부 정보 섹션에서는 토큰 사용량의 증분 변경 사항(델타)과 총합을 모두 제공하여 대화 중 사용량을 정확하게 모니터링할 수 있습니다.

완료

모델은 원래 식별자와 대화가 어떻게 끝났는지를 나타내는 `stopReason`이 포함된 `completionEnd` 이벤트를 전송합니다. 이 이벤트 계층 구조는 애플리케이션이 응답의 어느 부분이 함께 속하는지 추적하고 그에 따라 처리하여 여러 턴에 걸쳐 대화 컨텍스트를 유지할 수 있도록 합니다.

출력 이벤트 흐름은 응답 생성 단계로 들어가면서 시작됩니다. 자동 음성 인식으로 시작하여 사용할 도구를 선택하고, 음성을 트랜스크립션하고, 오디오를 생성하고, 트랜스크립션을 완료하고, 세션을 끝냅니다.



출력 이벤트 흐름

이 섹션에서는 출력 이벤트 흐름의 구조를 설명합니다.

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": "TOOL_USE",
      "type": "TOOL"
    }
  }
}

```

5. AudioOutputContent

ContentStart

```

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

```

AudioOutput

```

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

```

ContentEnd

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


6. CompletionEndEvent

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

감청

개입을 통해 사용자는 자연스러운 사람의 대화와 같이 말하는 동안 AI 어시스턴트 발언을 중단할 수 있습니다. 어시스턴트가 발언을 마칠 때까지 기다리는 대신 사용자는 새 정보로 개입하거나 이전 설명을 수정 또는 명확히 하거나 대화를 다른 주제로 리디렉션하거나, 충분히 들었으면 어시스턴트를 중지할 수 있습니다. 이렇게 하면 보다 자연스럽게 응답성이 뛰어난 대화 경험이 구축됩니다.

다음 다이어그램에서는 전체 개입 대화 흐름을 보여줍니다.



Amazon Nova 2 Sonic이 개입을 처리하는 방법

Amazon Nova 2 Sonic은 중단을 정상적으로 처리하도록 설계되었습니다. 사용자가 응답 중에 말을 시작하면 시스템은 즉시 현재 응답 생성을 중지하고 전체 대화 컨텍스트를 유지하며 클라이언트에 중단 신호를 보내고 새 사용자 입력을 처리하기 시작합니다.

컨텍스트 보존: 중단된 경우에도 Nova Sonic은 중단 전의 내용, 논의 중인 주제, 대화 기록 및 이전 턴의 관련 컨텍스트를 기억합니다. 이렇게 하면 일관되고 자연스러운 대화를 유지합니다.

클라이언트 측 구현 요구 사항

Amazon Nova 2 Sonic은 서버 측에서 개입을 처리하지만 완전한 경험을 위해 사용자가 클라이언트 측 로직을 구현해야 합니다.

오디오 대기열 문제: 오디오 생성이 재생 속도보다 빠릅니다. 이는 다음을 의미합니다.

- Nova Sonic에서 오디오 청크를 빠르게 생성함
- 클라이언트가 이러한 청크를 수신하고 대기열에 넣습니다.
- 클라이언트가 정상 발화 속도로 이를 재생합니다.

- 개입이 발생하면 오디오가 이미 재생 대기 중인 것입니다.

필수 클라이언트 측 로직: 애플리케이션이 다음과 같은 4가지 주요 단계를 처리해야 합니다.

1. 중단 신호 감지: Nova Sonic에서 중단 이벤트를 대기하고, 수신되면 즉시 대응합니다.
2. 현재 재생 중지: 현재 재생 중인 오디오를 일시 중지하고 중간 재생 상태인 모든 오디오를 중지합니다.
3. 오디오 대기열 지우기: 대기 중인 모든 오디오 청크를 제거하고 중단된 응답에서 버퍼링된 오디오를 모두 버립니다.
4. 새 오디오 시작: 새로 수신한 오디오 재생을 시작하고 일반 재생 흐름을 재개합니다.

턴 기반 제어 가능성

턴 기반 방식은 자연스러운 대화의 기본적인 양상입니다. Amazon Nova 2 Sonic은 `turnDetectionConfiguration` 파라미터를 통해 AI의 해당 발언 턴을 세밀하게 제어합니다. 이를 통해 여러 사용 사례에 맞게 대화 흐름을 최적화하여 응답성과 정확성의 균형을 맞출 수 있습니다. `endpointingSensitivity` 파라미터는 Amazon Nova 2 Sonic이 사용자의 턴 종료를 감지하고 응답을 시작하는 속도를 제어합니다. 이 설정은 응답 지연 시간과 여전히 발화 상태인 사용자를 중단할 가능성에 영향을 미칩니다.

API 구성

`sessionStart` 이벤트에서 턴 감지 민감도를 구성합니다.

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

}

민감도 수준

endpointingSensitivity 파라미터는 HIGH, MEDIUM, LOW의 세 가지 값을 허용합니다. 각 수준은 응답 속도와 여전히 발화 상태인 사용자를 중단할 위험 간의 균형을 맞춥니다.

높음

지연 시간에 최적화된 가장 빠른 응답 시간입니다. Nova Sonic은 음성의 끝을 감지한 후 최대한 빨리 응답합니다. 일시 중지 지속 시간: 1.5초. 빠른 질문과 답변, 명령 및 제어 애플리케이션, 시간에 민감한 상호 작용에 가장 적합합니다.

중간

중간 수준의 응답 시간을 사용하는 균형 잡힌 접근 방식입니다. 응답성을 유지하면서 거짓 긍정을 줄입니다. 일시 중지 지속 시간: 1.75초. 일반적인 대화, 복잡한 쿼리가 있는 고객 서비스, 멀티턴 논의에 가장 적합합니다.

낮음

최대 인내심으로 응답 시간이 가장 느립니다. Nova Sonic은 응답하기 전에 가장 오래 대기하며 생각 중에 일시 중지하는 사용자의 중단을 최소화합니다. 일시 중지 지속 시간: 2초. 신중한 대화, 나이가 많거나 언어 장애가 있는 사용자와의 대화, 복잡한 문제 해결에 가장 적합합니다.

일시 중지 지속 시간 참조

민감도 수준	일시 중지 지속 시간(초)
High(빠름)	1.5
중간	1.75
Low(느림)	~2.0

교차 모달 입력

Amazon Nova 2 Sonic은 이제 교차 모달 입력을 지원하므로 대화 세션 중에 음성 입력 외에도 문자 메시지를 보낼 수 있습니다. 음성은 여전히 기본 상호 작용 모드이지만 텍스트 입력은 입력이 더 편리하거나 적절한 시나리오에서 유연성을 제공합니다.

연속 스트리밍 필요: 교차 모달 입력이 제대로 작동하려면 활성 스트리밍 세션이 필요합니다. 세션은 일반 음성 세션처럼 연속 스트리밍을 유지 관리해야 합니다. 그렇지 않으면 표준 세션 제한 시간이 적용되고 연결이 종료됩니다.

교차 모달 텍스트 입력에서 민감도 수준은 다음과 같은 시나리오에 유용합니다.

- 클라이언트 측 앱 통합(웹 및 모바일): 사용자가 텍스트와 음성을 모두 사용하여 애플리케이션과 상호 작용함으로써 원활한 멀티모달 경험을 지원합니다.
- '모델 우선 시작' 사용 사례: 세션이 시작되면 즉시 문자 메시지를 전송하여 모델에 발화를 시작하라는 프롬프트를 표시할 수 있습니다.
- 비동기식 도구 직접 호출 중 모델 안내: toolUse 이벤트가 트리거되고 시스템이 도구 직접 호출 처리를 시작하면 클라이언트는 자연스러운 응답을 제공하기 위해 기다리는 동안 Sonic에 다음과 같은 문자 메시지를 보냅니다. '정보를 처리하는 동안 잠시 대기합니다. 그 동안 다른 도움이 필요하신가요?'
- 텔레포니 DTMF 통합: 고객은 전화 키패드를 사용하여 민감한 정보(예: 신용 카드 번호)를 입력합니다. 참고: Amazon Nova Sonic은 DTMF 어조를 기본적으로 처리하지 않습니다. DTMF 입력을 지원하려면 시스템에서 어조를 감지하고 텍스트(예: '1234')로 변환한 다음 Nova 2 Sonic으로 전송해야 합니다.

작동 방식

교차 모달 입력은 오디오 입력과 유사한 3개의 이벤트 시퀀스를 사용합니다.

1. 콘텐츠 시작 이벤트: 텍스트 입력의 시작 신호 전송
2. 텍스트 입력 이벤트: 실제 텍스트 메시지 포함
3. 콘텐츠 종료 이벤트: 텍스트 입력 완료 신호 전송

세 이벤트 모두 시퀀스를 유지 관리하려면 동일한 promptName 및 contentName을 사용해야 합니다. 적절한 멀티턴 대화 추적을 위해 텍스트 입력을 보낼 때마다 contentName에 대해 새 UUID를 생성해야 합니다.

이벤트 구조

1. 콘텐츠 시작 이벤트

구성 세부 정보와 함께 텍스트 입력 시퀀스를 시작합니다.

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

```

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

```

키 파라미터:

- **promptName**: 대화 프롬프트의 이름(세션에서 일관됨)
- **contentName**: 이 텍스트 입력의 고유 식별자(각 메시지에 대해 새 UUID 생성)
- **role**: 사용자 입력을 나타내려면 "USER"로 설정
- **type**: 텍스트 입력의 경우 "TEXT"로 설정
- **interactive**: 대화형 모드를 활성화하려면 true로 설정
- **mediaType**: 일반 텍스트 콘텐츠의 경우 "text/plain"으로 설정

2. 텍스트 입력 이벤트

실제 텍스트 메시지 콘텐츠를 포함합니다.

```

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

```

키 파라미터:

- **promptName**: 콘텐츠 시작 이벤트의 값과 일치해야 함
- **contentName**: 콘텐츠 시작 이벤트의 값과 일치해야 함

- **role:** 텍스트 메시지 문자열

3. 콘텐츠 종료 이벤트

텍스트 입력 완료 신호를 전송합니다.

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

키 파라미터:

- **promptName:** 이전 이벤트의 값과 일치해야 함
- **contentName:** 이전 이벤트의 값과 일치해야 함

언어 지원 및 다국어 기능

Amazon Nova 2 Sonic은 여러 언어로 다양한 음성을 제공하므로 사용자에게 자연스럽게 문화적으로 적합한 대화형 AI 애플리케이션을 생성할 수 있습니다. 각 언어는 여성스러운 음성 옵션과 남성스러운 음성 옵션을 모두 제공합니다.

다음 표에는 사용 가능한 모든 음성과 해당되는 언어 로캘이 나와 있습니다.

언어	Locale	여성스러운 음성 ID	남성스러운 음성 ID
영어(미국)	en-US	tiffany	matthew
영어(영국)	en-GB	amy	-
영어(호주)	en-AU	Olivia	-
영어(인도)	en-IN	Kiara	Arjun
프랑스어	fr-FR	ambre	florian

언어	Locale	여성스러운 음성 ID	남성스러운 음성 ID
이탈리아어	it-IT	beatrice	lorenzo
독일어	de-DE	Tina	lennart
스페인어(미국)	es-US	lupe	carlos
포르투갈어	pt-BR	Carolina	Leo
힌디어	hi-IN	Kiara	Arjun

애플리케이션에서 음성을 사용하는 이벤트 구조

promptStart 이벤트에서 프롬프트를 시작할 때 audioOutputConfiguration에서 음성 ID를 지정할 수 있습니다.

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

다국어 지원

Amazon Nova 2 Sonic은 여러 언어에서 자연스러운 대화를 지원하는 강력한 다국어 기능을 제공합니다. 서비스는 다국어 음성(여러 언어로 발화) 및 코드 스위칭(동일한 문장 내에서 언어 혼합)을 모두 지원하므로 진정한 글로벌 대화형 애플리케이션을 빌드할 수 있습니다.

TIFFANY(en-US, 여성) 및 MATTHEW(en-US, 남성)는 지원되는 모든 언어를 말할 수 있는 고유한 다국어 지원 음성입니다.

1. 영어
2. 프랑스어
3. 이탈리아어
4. 독일어
5. 스페인 요리
6. 포르투갈어
7. 힌디어

이를 통해 Tiffany와 Matthew는 여러 언어 사이를 원활하게 전환해야 하는 애플리케이션에 적합합니다.

채팅 기록 관리


Amazon Nova 2 Sonic 응답에는 사용자 음성과 어시스턴트 음성 모두에 대한 자동 음성 인식(ASR) 트랜스크립트가 포함됩니다. 채팅 기록 저장은 로깅 목적뿐만 아니라 예기치 않게 연결이 종료될 때 세션을 재개하는 경우에도 모범 사례입니다. 이를 통해 클라이언트가 컨텍스트를 다시 Nova Sonic으로 보내 대화를 원활하게 계속할 수 있습니다.

채팅 기록 관리에 대한 자세한 내용은 다음 리소스를 참조하세요.

1. [채팅 기록 로깅](#)
2. [대화 재개](#)

채팅 기록 전송

시스템/음성 프롬프트 후 오디오 스트리밍이 시작되기 전에 한 번만 대화 기록을 포함할 수 있습니다. 전체 채팅 기록은 40KB보다 클 수 없습니다. 다음 다이어그램에서는 이벤트 수명 주기 동안 채팅 기록이 전달되는 시점을 보여줍니다.



각 기록 메시지에는 contentStart, textInput, contentEnd의 세 가지 이벤트가 필요합니다.

메시지당 이벤트 스키마:

- contentStart - 메시지 역할 및 구성 정의

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

- textInput - 실제 메시지 콘텐츠를 포함합니다. 하나의 textInput은 1KB보다 클 수 없습니다. 그렇다면 동일한 콘텐츠 블록에서 여러 textInputs로 분할합니다. 대화가 40KB보다 큰 경우 전체 채팅 기록을 자릅니다.

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

- contentEnd - 메시지의 끝 표시

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

```
}
}
```

채팅 기록의 각 메시지에 대해 USER와 ASSISTANT 역할을 번갈아 이 세 가지 이벤트를 반복합니다.

중요 고려 사항:

- 채팅 기록은 세션당 한 번만 포함할 수 있음
- 채팅 기록은 시스템 프롬프트 이후 및 오디오 스트리밍이 시작되기 전에 전송되어야 함
- 오디오 스트리밍을 시작하기 전에 모든 기록 메시지를 전송해야 함
- 각 메시지는 USER 또는 ASSISTANT 역할을 지정해야 함
- textOutput 이벤트에서 저장된 트랜스크립트 콘텐츠를 textInput의 콘텐츠 값으로 사용

ASR 트랜스크립트 수신

대화 중에 Amazon Nova 2 Sonic은 출력 이벤트를 통해 ASR 트랜스크립트를 전송합니다. 각 트랜스크립트는 contentStart, textOutput, contentEnd의 세 가지 이벤트 시퀀스로 전달됩니다.

예제: 사용자 음성 트랜스크립트:

1. contentStart - 트랜스크립트의 시작을 나타냅니다.

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

2. textOutput - 실제 트랜스크립트 콘텐츠를 포함합니다.

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

3. contentEnd - 트랜스크립트의 끝을 표시합니다.

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

USER 및 ASSISTANT 역할 모두에 동일한 세 가지 이벤트 패턴이 적용됩니다. textOutput 이벤트에서 content 필드를 추출하고 contentStart 이벤트에서 role 필드를 추출하여 채팅 기록을 작성합니다.

모범 사례

항상 채팅 기록을 저장하여 다음을 지원합니다.

- 서로 다른 디바이스에서 세션 재개
- 대화 로깅 및 감사
- 후속 상호 작용을 위해 컨텍스트 보존

중요: 채팅 기록을 저장할 때 generationStage를 기반으로 텍스트 출력을 사용합니다.

- 추측 - 오디오 합성이 시작되기 전에 생성되는, Nova 2 Sonic에서 말하려는 내용의 미리 보기
- 최종 - 오디오 응답에서 말한 내용의 실제 문장 수준 트랜스크립션

대화의 정확한 레코드를 나타내므로 항상 채팅 기록에 최종 텍스트 출력을 저장합니다.

FINAL 출력 예제(채팅 기록에 저장):

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

SPECULATIVE 출력 예제(기록에 대해서가 아닌 선택적 미리 보기):

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

도구 구성


Amazon Nova 2 Sonic은 도구 사용(함수 직접 호출이라고도 함)을 지원하므로 모델은 API 직접 호출, 데이터베이스 쿼리 또는 사용자 지정 코드 함수와 같이 대화 중에 외부 정보 또는 작업을 요청할 수 있습니다. 이를 통해 음성 어시스턴트는 사용자 요청을 기반으로 작업을 수행하고, 정보를 검색하며, 외부 서비스와 통합할 수 있습니다.

Nova 2 Sonic은 비동기식 도구를 직접 호출하여 도구가 백그라운드에서 실행되는 동안 AI가 자연스럽게 계속 대화함으로써 보다 유동적이고 응답성이 뛰어난 사용자 환경을 구축하도록 지원합니다.

다음은 도구 사용 방법에 대한 단순화된 단계입니다.

1. 도구 정의: `promptStart` 이벤트에서 해당 파라미터를 사용하여 사용 가능한 도구 지정
2. 사용자 발화: 사용자가 도구를 요구하는 요청(예: '시애틀 날씨는 어떨까요?')
3. 도구 간접 호출: Nova 2 Sonic은 필요성을 인식하고 `toolUse` 이벤트를 전송함
4. 역할 실행: 애플리케이션이 도구를 실행하고 결과를 반환함
5. 응답 생성: Nova 2 Sonic은 결과를 음성 응답에 통합함

다음 다이어그램에서는 도구 사용의 작동 방식을 보여줍니다.



도구 정의

도구는 용도, 파라미터 및 예상 입력을 설명하는 JSON 스키마를 사용하여 정의됩니다.

다음은 도구 정의 구성 요소 및 설명입니다.

- Name: 도구의 고유 식별자(snake_case 사용)
- Description: 도구가 수행하는 작업에 대한 명확한 설명, AI가 도구 사용 시점을 결정하는 데 도움이 됨
- InputSchema: 도구가 허용하는 파라미터를 정의하는 JSON 스키마
- Properties: 유형 및 설명을 포함하는 개별 파라미터
- Required: 제공해야 하는 파라미터 이름 배열

도구 정의 예제

다음은 단순한 날씨 도구 정의입니다.

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


PromptStart에서 도구 구성

도구 구성은 오디오 및 텍스트 출력 설정과 함께 promptStart 이벤트에서 Nova 2 Sonic으로 전달됩니다.

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

도구 선택 파라미터

Nova 2 Sonic은 도구의 사용 시점과 사용할 도구를 제어하기 위해 세 가지 도구 선택 파라미터를 지원합니다. 도구 구성에서 toolChoice 파라미터를 지정합니다.

- **Auto(기본값):** 모델은 도구가 필요한지를 결정하고 필요한 경우 여러 도구를 직접 호출할 수 있습니다. 유연성을 극대화합니다.
- **Any:** 모델이 가장 적절한 도구를 선택할 수 있도록 응답 시작 위치에서 사용 가능한 도구 중 하나 이상이 직접 호출되도록 합니다. 지식 베이스나 도구가 여러 개 있고 이 중 하나가 사용되도록 보장하려는 경우에 유용합니다.
- **Tool:** 응답 시작 시 명명된 특정 도구를 정확히 한 번 강제로 직접 호출합니다. 예를 들어 지식 베이스 도구를 지정하면 모델이 해당 도구가 필요하다고 판단하는지에 관계없이 응답 전에 이를 쿼리합니다.

도구 선택 예제

Auto(기본값)

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

임의:

```
"toolChoice": {
```

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

특정 도구:

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

도구 사용 이벤트 수신 및 처리

Amazon Nova 2 Sonic에서 도구가 필요하다고 판단하면 다음이 포함된 toolUse 이벤트를 전송합니다.

1. toolUseID: 이 도구의 간접 호출에 대한 고유 식별자
2. ToolName: 실행할 도구 이름
3. 콘텐츠: 사용자의 요청에서 추출된 파라미터를 포함하는 JSON 문자열
4. SessionID: 현재 세션 식별자
5. Role: 도구 사용 이벤트에 대해 'TOOL'로 설정

도구 사용 이벤트 예제

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

처리 단계

1. Nova 2 Sonic에서 toolUse 이벤트 수신
2. 이벤트에서 도구 이름 및 파라미터 추출
3. 도구 로직 실행(API 직접 호출, 데이터베이스 쿼리 등)
4. toolResult 이벤트를 사용하여 결과 반환

ToolResult 이벤트 예제

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

모범 사례

- 명확한 설명: Nova 2 Sonic이 각 도구를 언제 사용해야 하는지 이해하는 데 도움이 되는 자세한 도구 설명을 작성합니다.
- 파라미터 검증: 오류를 방지하기 위해 실행 전에 항상 도구 파라미터를 검증합니다. 가능하면 서술형 문자열 대신 정형 데이터 유형(예: 열거형, 숫자 또는 부울)이 있는 적절한 JSON 스키마를 사용하여 도구 파라미터를 정의합니다.
- 오류 처리: 도구가 실패하면 toolResult 이벤트에서 의미 있는 오류 메시지를 반환합니다.
- 비동기식 실행: 비동기식 도구 직접 호출을 활용하여 대화 흐름을 유지 관리합니다.
- 도구 이름 지정: 설명이 포함된 작업 중심의 이름(예: get_weather, search_database, send_email)을 사용합니다.

비동기식 도구 직접 호출

AI에서 도구 결과를 자동으로 기다리는 기존 동기식 도구 직접 호출과 달리, Amazon Nova 2 Sonic의 비동기식 접근 방식을 사용하면 다음을 수행할 수 있습니다.


- 도구가 실행되는 동안 계속 사용자 입력 수락
- 보류 중인 도구 결과를 기다리지 않고 새 질문에 응답

- 여러 도구 직접 호출을 동시에 처리
- 어색한 일시 중지 없이 자연스러운 대화 흐름 유지 관리
- 추가 구성이 필요하지 않습니다. 비동기식 도구 직접 호출은 즉시 작동합니다.

작동 방식

Nova 2 Sonic이 도구 직접 호출을 실행하는 경우 대화를 일시 중지하지 않습니다. 대신 도구가 도착할 때까지 자연스럽게 듣고 응답합니다.


Asynchronous Tool Calling Flow



사용자 중단 처리

도구가 실행되는 동안 사용자가 요청을 변경하면 Nova 2 Sonic은 보류 중인 도구 직접 호출을 취소하지 않고 이를 지능적으로 처리합니다.

Async Tool Calling with User Interruption



예제 시나리오

```

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]
  
```

작동 방식

도구 결과가 항상 전달됨: 도구 직접 호출이 완료되면 사용자가 요청을 변경한 경우에도 해당 결과가 항상 모델로 전송됩니다. 모델은 추론 기능을 사용하여 정보를 처리하는 방법을 결정합니다.

컨텍스트 인식 처리: 모델은 대화 컨텍스트를 이해하고 오래된 도구 결과를 적절하게 처리할 수 있습니다. 예제:

- 사용자가 마음을 바꾼 후 '감사합니다'라고 말하더라도 모델에는 컨텍스트에 대한 원래 결과가 필요합니다.
- 사용자가 요청을 변경하면 모델은 원래 결과를 확인하면서 새 요청에 집중할 수 있습니다.

자동 취소 없음: 시스템은 새 사용자 입력을 기반으로 도구 직접 호출을 자동으로 취소하거나 무시하지 않습니다. 이를 통해 모델은 대응 방법에 대한 지능적인 의사 결정을 내릴 수 있도록 완전한 정보를 확보합니다.

통합

Amazon Nova 2 Sonic을 다양한 프레임워크 및 플랫폼과 통합하여 대화형 AI 애플리케이션을 빌드할 수 있습니다. 이러한 통합을 통해 일반적인 사용 사례에 대해 미리 구축된 구성 요소와 단순화된 API가 제공됩니다.

Strands Agents

Strands Agents는 AI 에이전트를 빌드하고 실행하는 모델 기반 접근 방식을 채택하는 단순하지만 강력한 SDK입니다. 단순한 대화형 어시스턴트부터 복잡한 자율 워크플로, 로컬 개발부터 프로덕션 배포에 이르기까지 Strands Agents는 필요에 따라 규모가 조정됩니다.

Strands 프레임워크에 대한 포괄적인 설명서는 [공식 Strands 설명서](#)를 참조하세요.

Strands BidiAgent에서는 영구 스트리밍 연결을 통해 실시간 오디오 및 텍스트 상호 작용을 제공합니다. 기존 요청-응답 패턴과 달리, 이 에이전트는 중단, 동시 처리 및 지속적인 오디오 응답을 지원하여 장기 대화를 유지 관리합니다.

사전 조건:

- Python 3.8 이상 설치
- Amazon Bedrock에 대한 액세스 권한으로 구성된 AWS의 자격 증명
- Python async/await 구문에 대한 기본적인 지식

코드 예제:

코드 예제

설치:

필수 패키지를 설치합니다.

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

다음 예제를 실행합니다.

```
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. 가져오기: 필수 모델

```
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: 양방향 대화를 오케스트레이션하는 기본 에이전트 클래스
- BidiAudioIO: 음성 상호 작용에 대한 오디오 입력 및 출력 처리
- BidiTextIO: 트랜스크립션 및 응답에 대한 텍스트 출력 제공
- BidiNovaSonicModel Nova 2 Sonic 모델 래퍼
- Calculator: 수학 작업을 위한 사전 빌드된 도구

2. 오디오 및 텍스트 I/O 구성

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

BidiAudioIO는 마이크 입력 및 스피커 출력을 관리하는 반면, BidiTextIO는 콘솔에 텍스트 트랜스크립션 및 응답을 표시합니다.

3. 모델 초기화

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

Nova Sonic 모델 인스턴스를 생성합니다. 리전 파라미터는 모델이 배포되는 AWS 리전을 지정합니다.

4. 에이전트 생성 및 실행

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

에이전트는 다음을 사용하여 생성됩니다.

- 모델: 사용할 Nova 2 Sonic 모델
- 도구: 에이전트가 직접 호출할 수 있는 도구 목록(예: 계산기)
- 입력: 마이크의 오디오 입력
- 출력: 화자로의 오디오 출력 및 콘솔로의 텍스트 출력


프레임워크 통합

Amazon Nova 2 Sonic을 다양한 프레임워크 및 플랫폼과 통합하여 정교한 음성 애플리케이션을 빌드할 수 있습니다. 다음 예제에서는 널리 사용되는 프레임워크와의 통합 패턴을 보여줍니다.

Amazon Bedrock AgentCore

Amazon Bedrock AgentCore는 엔터프라이즈급 보안 및 확장성을 갖춘 Nova 2 Sonic 애플리케이션을 배포하기 위한 관리형 런타임 환경을 제공합니다. AgentCore는 인프라, 인증 및 WebSocket 연결을 처리하여 실시간 음성 AI 애플리케이션의 배포를 단순화합니다.

AgentCore Architecture



주요 기능:

- 양방향 스트리밍 - 실시간 이벤트 처리 및 짧은 지연 시간 통신을 바탕으로 Nova Sonic의 전이중 스트리밍 인터페이스에 대한 기본 지원.
- WebSocket 인프라 - 자동 조정, 연결 관리 및 오류 복구를 지원하는 프로덕션 지원 WebSocket 서버.
- 컨테이너 배포 - 수평적 스케일링 및 독립 버전 관리를 통해 Nova Sonic 애플리케이션을 관리형 인프라에 컨테이너로 배포합니다.
- 엔터프라이즈 보안 - IAM 및 SigV4를 통한 세분화된 인증, VPC 격리 및 포괄적인 감사 로깅.

아키텍처는 클라이언트 애플리케이션이 SigV4 인증을 사용하여 WebSocket을 통해 AgentCore 런타임에 연결하는 방법을 보여줍니다. 컨테이너화된 환경에는 WebSocket 서버, 애플리케이션 로직 및 Nova Sonic 클라이언트가 포함되며, 모두 양방향 스트리밍 API를 통해 Nova Sonic과 통신합니다.

이점:

- 단순화된 작업: AgentCore가 인프라, 규모 조정 및 신뢰성을 관리하는 동안 애플리케이션 로직에 집중합니다.
- 엔터프라이즈 보안: 프로덕션 배포에 대한 기본 제공 인증, 권한 부여 및 규정 준수 기능.
- 비용 효율성: 자동 조정 및 리소스 최적화에서 사용한 만큼만 비용을 지불합니다.
- 개발자 생산성: 관리형 WebSocket 인프라 및 컨테이너 배포를 통해 프로덕션으로 이전 시간을 단축합니다.

사용 사례


- 보안 인증을 사용하는 고객 서비스 음성 어시스턴트
- IAM 통합이 필요한 엔터프라이즈 음성 애플리케이션
- 격리된 배포가 포함된 다중 테넌트 음성 플랫폼
- 규정 준수 및 감사 추적이 필요한 음성 지원 애플리케이션

AgentCore를 사용하여 Nova Sonic을 배포하는 방법에 대한 자세한 내용은 [Amazon Bedrock AgentCore 설명서](#)를 참조하세요.

LiveKit

LiveKit은 실시간 오디오 및 비디오 애플리케이션을 빌드하기 위한 오픈 소스 플랫폼입니다. Amazon Nova 2 Sonic과의 통합을 통해 개발자는 복잡한 오디오 파이프라인 또는 신호 프로토콜을 관리하지 않고도 대화형 음성 인터페이스를 빌드할 수 있습니다.

자세한 구현 예제와 코드 예제는 [LiveKit AWS 통합 설명서](#)를 참조하세요.



작동 방식:

- 클라이언트 계층: 웹, 모바일 또는 데스크톱 애플리케이션은 오디오 캡처, WebRTC 스트리밍 및 재산을 처리하는 LiveKit의 클라이언트 SDK를 사용하여 연결됩니다.
- LiveKit 서버: 실시간 통신 허브 역할을 수행하며 WebRTC 연결을 관리하고, 오디오 스트림을 라우팅하며, 지연 시간이 짧은 최적화로 세션 상태를 처리합니다.
- LiveKit 에이전트: 서버에서 오디오를 수신하여 Nova Sonic 플러그인을 통해 이를 처리하고 응답을 다시 스트리밍하는 Python 기반 에이전트입니다. 음성 활동 탐지 및 턴 관리와 같은 기본 제공 기능을 포함합니다.

- Amazon Nova 2 Sonic: 양방향 스트리밍 API를 통해 오디오 스트림을 처리하면서 음성 인식과 자연어 이해를 수행하고 합성된 음성으로 대화 응답을 생성합니다.


Pipecat

Pipecat은 음성 및 멀티모달 대화형 AI 애플리케이션을 빌드하기 위한 프레임워크입니다. Amazon Nova Sonic 및 기타 AWS 서비스를 사용하여 지능형 음성 애플리케이션을 생성하기 위해 여러 구성 요소를 오케스트레이션하는 모듈식 파이프라인 기반 아키텍처를 제공합니다.

자세한 구현 예제 및 코드 샘플은 [PipeCat AWS 통합 설명서](#)를 참조하세요.

주요 기능:

- 파이프라인 아키텍처: ASR, NLU, TTS 등을 비롯해 음성 AI 구성 요소를 구성하기 위한 모듈식 Python 기반 프레임워크.
- Pipecat 흐름: 복잡한 대화형 로직 및 도구 실행을 구축하기 위한 상태 관리 프레임워크.
- WebRTC 지원: 실시간 오디오 스트리밍에 대한 Daily 및 기타 WebRTC 제공업체와의 기본 제공 통합.
- AWS 통합: Amazon Bedrock, Amazon Transcribe 및 Amazon Polly에 대한 기본 지원입니다.



아키텍처에는 다음이 포함됩니다.

- WebRTC 전송: 클라이언트 디바이스와 애플리케이션 서버 간 실시간 오디오 스트리밍.
- 음성 활동 탐지(VAD): 구성 가능한 음성 탐지 및 노이즈 억제 기능이 있는 Silero VAD.
- 음성 인식: 정확한 실시간 음성-텍스트 변환을 위한 Amazon Transcribe.
- 자연어 이해: 지연 시간에 최적화된 추론을 지원하는 Bedrock 기반 Amazon Nova Pro.
- 도구 실행: API 통합 및 백엔드 서비스 직접 호출을 위한 Pipecat 흐름.
- 응답 생성: 일관된 컨텍스트 인식 응답을 위한 Amazon Nova Pro.
- 텍스트-음성: 생생한 음성 출력을 위한 생성형 음성을 사용하는 Amazon Polly.


AWS에 배포

AWS 클라우드 개발 키트(CDK)와 함께 코드형 인프라를 사용하여 AWS에 Nova Sonic 애플리케이션을 배포합니다. 이 접근 방식에서는 모범 사례가 기본적으로 제공되는 반복 가능한 버전 제어 배포를 제공합니다.

배포 옵션

- Amazon Elastic Container Service(ECS): Application Load Balancer 통합, 오토 스케일링 및 서버리스 Fargate 실행을 통한 완전관리형 컨테이너 오케스트레이션.
- Amazon Elastic Kubernetes Services(EKS): 복잡한 오케스트레이션, 고급 네트워킹, 다중 리전 배포 및 광범위한 툴링 에코시스템을 위한 관리형 Kubernetes.
- AWS CDK: AWS CDK를 사용하면 익숙한 프로그래밍 언어를 사용하여 클라우드 인프라를 정의할 수 있습니다.

AWS CDK를 사용하여 Nova Sonic을 배포하는 완전한 프로덕션 지원 예제는 GitHub의 [Speech-to-Speech CDK Sample](#)을 참조하세요. 이 샘플에서 보여 주는 작업은 다음과 같습니다.



- TypeScript를 사용하여 CDK 인프라 설정 완료
- 실시간 통신을 위한 WebSocket 서버 구현
- ECS 및 Fargate를 사용하는 컨테이너 배포

- WebSocket 지원을 위한 Application Load Balancer 구성
- VPC 네트워킹 및 보안 그룹 설정
- CloudWatch 모니터링 및 로깅
- 프로덕션 배포 모범 사례


다중 에이전트 시스템

다중 에이전트 아키텍처는 복잡한 태스크를 처리하는 AI 어시스턴트를 설계하는 데 널리 사용되는 패턴입니다. Nova 2 Sonic에서 지원하는 음성 어시스턴트에서 이 아키텍처는 여러 전문 에이전트를 조정하며, 각 에이전트는 독립적으로 작동하여 병렬 처리, 모듈식 설계 및 규모 조정 가능한 솔루션을 지원합니다.

Nova Sonic은 다중 에이전트 시스템에서 오케스트레이터 역할을 하며 다음과 같은 두 가지 주요 기능을 수행합니다.

대화 흐름 관리: 대화의 다음 단계를 진행하기 전에 필요한 모든 정보가 수집되었는지 확인합니다.

의도 분류: 사용자 문의를 분석하여 적절한 전문 하위 에이전트로 라우팅합니다.



위 다이어그램에서는 다중 에이전트 아키텍처를 사용하는 बैंकिंग 음성 어시스턴트를 보여줍니다. 대화 흐름은 인사말과 사용자 이름 수집으로 시작한 다음, 전문 하위 에이전트를 통해 बैंकिंग 또는 모기지와 관련된 문의를 처리합니다.

대화 흐름 예제:

1. 사용자가 음성 어시스턴트에 연결합니다.
2. Nova 2 Sonic: "안녕하세요! 이름은 어떻게 되세요?"
3. 사용자: "내 이름은 John이라고 해."
4. Nova 2 Sonic: "안녕하세요, John. 오늘 어떻게 도와드릴까요?"
5. 사용자: "내 계정 잔액을 확인하고 싶어."
6. Nova 2 Sonic: [인증 에이전트로 라우팅]
7. 인증 에이전트: "계정 ID를 제공하세요."
8. 사용자: "12345"
9. 인증 에이전트: [자격 증명 확인]
10. Nova 2 Sonic: [뱅크 에이전트로 라우팅]
11. बैंकिंग 에이전트: "현재 잔액은 5,431,10 USD입니다."

이 예제에서는 Amazon Bedrock AgentCore에 배포된 Strands Agents 프레임워크를 사용하는 하위 에이전트를 보여주지만, 이 아키텍처는 유연합니다. 선택 항목:

- 선호하는 에이전트 프레임워크
- 모든 LLM 공급자
- 사용자 지정 호스팅 옵션
- 여러 오케스트레이션 패턴

이점:

- 모듈성: 각 에이전트는 특정 도메인에 집중하므로 시스템을 더 쉽게 유지 관리하고 업데이트할 수 있습니다.
- 확장성: 기존 에이전트를 수정하지 않고도 새 에이전트를 추가하여 필요에 따라 시스템을 확장할 수 있습니다.
- 병렬 처리: 여러 에이전트가 동시에 작동하여 복잡한 쿼리의 응답 시간을 개선할 수 있습니다.

- 전문성: 가장 적합한 도구와 지식 베이스를 사용하여 각 에이전트를 특정 태스크에 맞게 최적화할 수 있습니다.
- 장애 격리: 한 에이전트가 실패해도 다른 에이전트는 계속 작동하여 전체 시스템 신뢰성을 개선합니다.

자세한 내용과 코드 예제는 [이 블로그](#)를 참조하세요.

실습 샘플은 [Nova Sonic Workshop Multi-Agent Lab](#)을 참조하세요.

텔레포니 통합

Amazon Nova 2 Sonic은 텔레포니 제공업체와 통합되어 전화를 통해 AI 기반 음성 애플리케이션에 액세스할 수 있습니다. 이 가이드에서는 고객 센터 솔루션 및 음성 에이전트를 빌드하기 위한 Twilio, Vonage 및 기타 SIP 기반 시스템과의 통합을 다룹니다.

Twilio: 프로그래밍 가능한 음성 및 미디어 스트리밍 기능을 갖춘 클라우드 통신 플랫폼.

Vonage: 음성, WebSocket 오디오 스트리밍 및 SIP 연결을 사용하는 글로벌 통신 API.

AWS는 실시간 분석 및 텔레포니 통합을 통해 고객 센터 환경에서 Nova Sonic을 보여주는 포괄적인 샘플 구현을 제공합니다.

리포지토리: [텔레포니를 사용하는 샘플 Sonic Contact Center](#)

Amazon Nova를 사용하는 고급 시스템

개요

이 섹션에서는 Nova 모델을 사용해 고급 패턴을 구현하는 고급 사용자를 위한 포괄적인 지침을 제공합니다. 이러한 기능은 도구 통합, 검색 증강 생성(RAG) 및 자율 AI 에이전트를 비롯한 정교한 애플리케이션을 지원합니다.

Amazon Nova 2에서 확장된 사고

Amazon Nova 2 Lite에서는 모델이 복잡한 문제에 대한 심층적인 추론에 참여할 수 있는 확장된 사고 기능을 도입했습니다. 이 선택적 기능을 사용하면 모델이 어려운 태스크를 고민할 때 추가 계산 리소스를 할당하는 시기와 방법을 제어할 수 있습니다.

확장된 사고의 작동 방식

Amazon Nova 2에서는 확장된 사고를 하이브리드 기능으로 도입합니다. 다음을 완벽하게 제어할 수 있습니다.

- 확장된 사고 꺼짐(기본값): Amazon Nova 2는 효율적인 잠재 추론으로 작동하며 일상적인 태스크와 대용량 애플리케이션에 적합합니다.
- 확장된 사고 켜짐: Amazon Nova 2는 심층 분석이 필요한 복잡한 문제에 가장 적합한 명시적 단계별 추론에 참여합니다.

추론 노력

다음은 다양한 수준의 추론 노력을 보여줍니다.

낮은 수준의 노력(maxReasoningEffort: "low")

적합한 작업: 체계적인 사고가 요구되는 복잡성이 늘어난 태스크. 예를 들어 모델이 기존 코드 품질을 신중하게 고려해야 하는 코드 검토 및 개선 제안, 여러 요인을 신중하게 고려해야 하는 분석 태스크 또는 방법론적 접근 방식의 이점을 활용하는 문제 해결 시나리오에 사용할 수 있습니다. 낮은 수준의 노력은 심층적인 여러 단계의 계획을 세우지 않고도 기본적인 추론을 통해 정확도가 향상되는 복합 태스크에 적합합니다.

중간 노력(maxReasoningEffort: "medium")

적합한 작업: 여러 단계의 태스크 및 코딩 워크플로. 예를 들어 변경 사항을 구현하기 전에 모델이 기존 코드 구조를 이해해야 하는 소프트웨어 개발 및 디버깅, 여러 파일 또는 구성 요소에서 조정이 필요한 코드 생성, 상호 종속성이 존재하는 여러 단계의 계산이나 여러 제약 조건이 있는 태스크 계획에 사용할 수 있습니다. 중간 노력은 여러 도구를 조정하고 모델이 여러 순차적 작업에서 컨텍스트를 유지 관리해야 하는 에이전트 워크플로에 적합합니다.

높은 수준의 노력(maxReasoningEffort: "high")

적합한 작업: STEM 추론 및 고급 문제 해결. 예를 들어 엄격한 단계별 확인, 심층 조사를 요구하는 과학 분석 및 연구 태스크, 여러 차원에서 아키텍처 고려 사항이 포함된 복잡한 시스템 설계 또는 중요한 영향을 미치는 중요한 의사 결정 시나리오가 필요한 고급 수학적 문제 및 증명에 사용할 수 있습니다. 높은 수준의 노력은 정교한 추론, 대안에 대한 신중한 평가, 결론에 대한 철저한 검증이 필요한 태스크에서 최대의 정확도를 제공합니다.

빠른 시작: 확장된 사고 활성화

확장된 사고는 reasoningConfig 파라미터를 통해 제어됩니다.

```
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"])

```

추론 파라미터:

- type: enabled 또는 disabled(기본값: disabled)
- maxReasoningEffort, low, medium 또는 high

Note

Temperature, topP, topK는 maxReasoningEffort를 high로 설정한 상태에서 사용할 수 없습니다. 이러한 파라미터를 함께 사용하면 오류가 발생합니다.

확장된 사고를 활용하는 코드의 전체 예제는 [the section called “코드 라이브러리”](#) 섹션을 참조하세요.

응답 구조

확장된 사고를 활성화하면 응답에는 reasoningContent 블록과 text 콘텐츠 블록이 순서대로 포함됩니다.

```

{
  "output": {
    "message": {
      "role": "assistant",
      "content": [
        {
          "reasoningContent": {
            "reasoningText": {

```

```

        "text": "[REDACTED]"
      }
    },
    {
      "text": "Based on the premises, we can conclude..."
    }
  ]
},
"stopReason": "end_turn"
}

```

Note

Amazon Nova 2에서 추론 콘텐츠는 [REDACTED]로 표시됩니다. 출력 품질 향상에 기여하므로 추론 토큰에 대한 요금은 계속 청구됩니다. 향후 릴리스에서 추론 콘텐츠를 노출하는 옵션을 유지하기 위해 이제 이 필드가 응답 구조에 포함됩니다. 모델 추론 프로세스를 설명하기 위한 최선의 접근 방식을 결정하기 위해 고객과 적극적으로 협력하고 있습니다. 추론 콘텐츠는 [REDACTED]로 표시됩니다. 출력 품질 향상에 기여하므로 추론 토큰에 대한 요금은 계속 청구됩니다.

구성 옵션

Amazon Nova 2에서는 추론을 활성화하기 위해 기존 Converse 요청 구조에 추가할 수 있는 새로운 `reasoningConfig` 파라미터를 도입합니다.

```

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

```

파라미터:

- `type`: "enabled" 및 "disabled" 사이에서 전환(기본값: "disabled")
- `maxReasoningEffort`: 활성화되면 추론 깊이 제어

- 'low': 다소 복잡한 태스크
- 'medium': 상당한 분석이 필요한 복잡한 문제
- 'high': 매우 복잡한 태스크에 대한 가장 철저한 추론

Note

"high"를 사용하는 경우 temp, topP 및 maxToken은 설정 해제해야 합니다. 이 모드에서 모델은 최상의 솔루션을 찾기 위해 심층 분석을 수행합니다. 이와 같이 보다 철저한 처리로 65k의 토큰을 초과하는 출력이 생성될 수 있습니다. 정확한 양은 요청의 복잡성에 따라 다르지만 일부 문제의 경우 최대 128k의 토큰이 생성되기도 합니다. 이를 통해 하면 잘린 결과가 아닌 완전한 고품질 추론을 얻을 수 있습니다.

지원되는 모델

확장된 사고는 현재 Amazon Nova 2 Lite(us.amazon.nova-2-lite-v1:0)에서 사용할 수 있음

도구 사용을 통한 확장된 사고

확장된 사고는 도구 직접 호출과 원활하게 작동하므로 Amazon Nova는 사용할 도구와 결과를 해석하는 방법을 추론할 수 있습니다.

추론 토큰 및 요금 이해

토큰 유형

확장된 사고 토큰은 출력 토큰으로 청구됩니다.

- 입력 토큰: 원래 요청 콘텐츠(표준 입력 요금)
- 출력 토큰: 여기에는 추론 토큰과 최종 표시 응답 콘텐츠(표준 출력 요금 적용)가 포함됩니다.

사용량 분석

세 가지 토큰 유형 모두 사용자의 사용량 지표 및 결제에 포함됩니다. 추론 토큰은 출력 토큰과 요금이 동일하며 모델 응답에 '삭제됨'으로 표시됩니다."

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

FAQ

Amazon Nova 2 Lite에서 모델의 사고 프로세스를 표시하는 대신 추론 콘텐츠에 대해 '삭제됨'을 표시하는 이유는 무엇인가요?

이번 출시의 주요 초점은 Nova 2가 태스크에 대해 동급 최고의 인텔리전스를 제공하도록 하는 것이며, 향상된 정확도에 잘 반영됩니다.

추론 프로세스에 대한 가시성이 중요하다는 점을 알고 있으며, 모델이 문제를 어떻게 생각하는지 이해하는 데 고객의 큰 관심을 끌었습니다.

현재 이 기능을 곧 제공하기 위한 방법을 살펴보고 있습니다.

추론 토큰은 출력 품질을 개선하는 실제 작업을 나타내므로 여전히 추론 토큰에 대한 요금이 청구됩니다.

응답 토큰과 함께 outputTokens에 캡처됩니다.

추론이 삭제되면 확장된 사고가 작동하는지 어떻게 알 수 있나요?

응답에서 출력에 reasoningContent 블록(추론이 활성화된 경우에만 표시됨)이 있는지 확인하여 확장된 사고가 작동하는지 확인할 수 있습니다.

도구 사용(함수 직접 호출)

도구는 모델을 API, 데이터베이스 및 코드 실행 환경과 같은 외부 기능에 연결하여 Amazon Nova 기능을 확장합니다. 도구를 사용하면 Amazon Nova에서 실시간 정보에 액세스하고, 계산을 수행하며, 외부 시스템과 상호 작용할 수 있습니다.

도구 사용 워크플로 이해

Amazon Nova에서 도구를 사용하는 경우 세 가지 주요 단계가 포함됩니다.

사용자 쿼리 및 도구 정의

각 도구의 기능과 입력 요구 사항을 설명하는 JSON 스키마를 제공하여 도구를 정의합니다. 도구 구성에는 각 도구를 사용하는 경우와 방법에 대한 명시적 세부 정보가 포함되어야 합니다.

도구 선택

사용자가 메시지를 전송하면 Amazon Nova에서 이를 분석하여 도구가 필요한지 결정합니다. 이 자동 도구 선택에서는 컨텍스트를 살펴보고 간접 호출할 도구(있는 경우)를 결정합니다. Amazon Nova에서 적절한 도구를 식별하면 도구 이름과 필요한 파라미터를 반환합니다.

모델의 요청에 따라 도구를 실행할 책임이 사용자에게 있습니다. 즉, 도구의 기능을 간접 호출하고 모델에서 제공하는 입력 파라미터를 처리하는 코드를 작성합니다.

결과 반환

도구를 실행한 후 JSON 또는 텍스트와 이미지 조합을 사용하여 결과를 구조화된 형식으로 Amazon Nova에 다시 보냅니다. Amazon Nova는 도구의 출력을 최종 응답에 통합합니다. 실행 중에 오류가 발생하면 Amazon Nova에서 적절히 조정할 수 있도록 도구 응답에 이를 표시합니다.

도구 생성

도구 배열과 선택적으로 도구 선택 파라미터를 포함하는 도구 구성을 사용하여 도구를 정의합니다. 각 도구 사양에는 다음이 포함되어야 합니다.

- 이름: 도구의 고유한 식별자
- 설명: 도구 기능에 대한 간결한 설명
- 입력 스키마: 필수 및 선택적 파라미터를 정의하는 JSON 스키마

Example도구 구성 예제

```
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"]
    }
}
]
}

```

도구 정의 모범 사례

- 이름과 설명이 도구의 정확한 기능을 명시적으로 전달하는지 확인하고, 지나치게 의미적으로 유사한 도구는 피함
- 모델이 유사한 도구를 구별하는 데 도움이 되도록 설명에 주요 차별화 요소 포함
- 최상의 성능을 위해 JSON 스키마를 중첩 계층 2개로 제한
- 일반 텍스트로 구조를 설명하는 대신 스키마 유형(예: enum, int, float)을 사용하여 입력 제한
- JSON 스키마 표기법을 사용하는 필수 파라미터와 선택적 파라미터 비교(예: "required": ["param1", "param2"]) 표시
- 제출하기 전에 표준 검사기를 사용하여 JSON 스키마 검증
- 스키마에서 긴 문자열 인수를 마지막에 배치하고 중첩하지 않도록 함

제한된 디코딩을 포함하는 구조화된 출력

Amazon Nova 모델은 제한된 디코딩을 활용하여 생성된 출력에서 높은 신뢰성을 보장합니다. 이 기법은 문법을 사용하여 각 생성 단계에서 가능한 토큰을 제한해 유효하지 않은 키포드를 방지하고 정의된 스키마를 기반으로 올바른 데이터 유형을 적용합니다.

Example 구조화된 출력 예제

```

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"}
  }
}

```

도구 선택 옵션

Amazon Nova는 세 가지 도구 선택 파라미터를 지원합니다.

도구

지정된 도구가 한 번 직접 호출되며, 구조화된 출력 사용 사례에 적합함

입의

제공된 도구 중 하나가 한 번 이상 직접 호출되며, API 선택 시나리오에 유용함

자동

모델에서 도구의 직접 호출 여부와 직접 호출할 도구 수(기본 동작)를 결정함

도구 직접 호출

Amazon Nova에서 도구를 직접 호출하기로 결정하면 도구 사용 블록이 어시스턴트 메시지의 일부로 반환하며 이때 stopReason은 'tool_use'로 설정됩니다. 도구 블록에는 도구의 이름과 해당 입력이 포함됩니다.

Note

단일 Python 세션에서 다음 코드 섹션을 순차적으로 실행합니다(도구 직접 호출 → 도구 결과 반환). 예제를 다시 실행하려면 Python 세션을 다시 시작합니다.

Example도구 직접 호출

```
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']}")

```

도구 직접 호출 처리

메시지에서 도구 이름과 인수를 추출하고 도구를 간접 호출합니다.

```
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"])

```

도구 결과 반환

ToolResultBlock 스키마를 사용하여 도구 결과를 반환합니다.

```

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}")

```

오류 처리

Amazon Nova에 오류를 다시 보고하여 요청 수정 및 재시도를 허용합니다.

```

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

```

보안 고려 사항

- 도구를 간접 호출하기 전에 도구가 존재하는지 검증
- 입력의 형식이 올바른지 확인
- 도구 실행 전에 적절한 권한이 있는지 확인
- Amazon Nova에서 사용자 정보를 도구 직접 호출에 주입하도록 허용하는 대신 세션 세부 정보에 의존
- LLM에서 도구 직접 호출을 할루시네이션할 수 있으므로, 실행 전에 항상 검증

기본 제공 시스템 도구

Amazon Nova 2.0 모델에는 사용자 지정 구현이 필요하지 않은 완전관리형 기본 제공 도구가 포함되어 있습니다. Converse API에서 간단하게 토글하여 이러한 도구를 활성화합니다.

코드 인터프리터

코드 인터프리터를 사용하면 Nova가 격리된 샌드박스 환경에서 Python 코드를 안전하게 실행할 수 있습니다. 이 도구는 수학 계산, 논리 연산 및 반복 알고리즘을 위해 설계되었습니다.

Note

코드 인터프리터는 IAD, PDX 및 NRT AWS 리전에서 사용할 수 있습니다. 요청이 지원되는 리전으로 라우팅되도록 하려면 글로벌 CRIS를 사용합니다. Bedrock API 키를 사용하는 경우 정책 정의에 InvokeTool 권한을 수동으로 추가해야 합니다. 기본 Bedrock 역할에서는 InvokeTool 작업을 허용하지 않습니다.

systemTool 파라미터를 지정하여 코드 인터프리터를 활성화합니다.

```
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"])

```

인터프리터는 샌드박스에서 코드를 실행하고 표준 스키마에서 결과를 반환합니다.

```

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

```

Web Grounding

Amazon Nova는 웹 그라운드링을 통해 인터넷에서 실시간 정보에 액세스하여 최신 응답을 제공하고 할루시네이션을 줄입니다. nova_grounding 시스템 도구를 지정하여 활성화합니다.

```

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

```

웹 그라운드링에 대한 자세한 내용은 [the section called “Web Grounding”](#) 섹션을 참조하세요.

Model Context Protocol(MCP)

Model Context Protocol(MCP)은 데이터 소스와 AI 기반 도구 간에 안전한 양방향 연결을 구축할 수 있는 개방형 표준입니다. 각 API 또는 서비스에 대한 사용자 지정 어댑터를 작성하는 대신, MCP 서버를 실행하고 Amazon Nova에서 클라이언트 브리지를 통해 도구를 자동으로 검색하도록 할 수 있습니다.

연결되면 Amazon Nova는 이러한 도구를 다른 외부 통합과 같이 처리합니다. 즉, 직접 호출 시점을 결정하고, 필요한 파라미터를 전송하며, 결과를 응답에 통합합니다. Amazon Nova를 Strands와 함께 사용하면 검색, 연결 및 결과 매핑을 자동으로 관리하는 기본 제공 MCPClient를 통해 작업을 더 쉽게 수행할 수 있습니다.

AI 에이전트 구축

Amazon Nova 모델은 Amazon Nova Act를 사용하여 AI 에이전트를 빌드하는 데 최적화되어 있습니다. 이 모델을 사용하면 도구 사용을 개선하고 여러 단계의 태스크에 대한 추론을 개선하며 여러 복잡한 에이전트 워크플로에서 컨텍스트를 유지 관리하는 기능을 향상시키고 원격 MCP 도구를 지원할 수 있습니다.

에이전트 생성

Nova로 빌드된 AI 에이전트는 여러 도구 직접 호출을 오케스트레이션하고, 확장된 여러 상호 작용에서 컨텍스트를 유지 관리하며, 필요한 경우 과정을 수정할 수 있습니다. 확장된 사고는 복잡한 목표를 통해 체계적 추론을 지원하여 에이전트 워크플로를 변환합니다. 에이전트 시스템의 계획 및 실행 프로세스를 보다 견고하게 만들려면 Strands Agents와 같은 계획 프레임워크 SDK를 사용하는 방법을 고려합니다.

에이전트 설계 패턴

Nova를 사용하여 에이전트를 설계하는 경우:

- 계획 및 확인이 필요한 복잡한 여러 단계의 워크플로에서 최상의 결과를 얻으려면 중간 또는 높은 수준의 추론 활성화
- 여러 에이전트 상호 작용에서 유연한 도구 선택을 위해 도구 선택 auto 구현
- 에이전트가 수정된 접근 방식으로 복구하고 재시도할 수 있도록 설계 오류 처리
- 대화 기록을 유지 관리하여 여러 에이전트 상호 작용에서 컨텍스트 보존
- 에이전트 시스템이 사용하는 제어되지 않는 여러 콘텐츠에서 강력한 콘텐츠 필터링 및 조정 메커니즘을 구현합니다. 예를 들어 Amazon은 여러 파운데이션 모델, 지식 베이스 및 에이전트에서 보호 기

능을 적용하도록 설계된 기능인 Amazon Bedrock 가드레일을 제공합니다. 이러한 가드레일은 유해한 콘텐츠를 필터링하고, 거부된 주제를 차단하며, 개인 식별 정보와 같은 민감한 정보를 삭제할 수 있습니다.

다중 도구 에이전트 예제

```
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"
        #}
    #}
#}
)

```

에이전트 간접 호출

에이전트 간접 호출에는 대화 흐름 관리, 도구 직접 호출 처리, 여러 상호 작용에서 상태 유지 관리가 포함됩니다.

에이전트 응답 스트리밍

응답을 스트리밍하여 에이전트의 추론 및 작업에 대한 실시간 가시성을 제공합니다.

```

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."
        #}]
    #}],
    #toolConfig=tool_config,
    #inferenceConfig={"maxTokens": 10000, "temperature": 1, "topP": 0.9},
    #additionalModelRequestFields={
        # "reasoningConfig": {
            # "type": "enabled",
            # "maxReasoningEffort": "low"
        #}
    #}
#}
)

```

```

    #}]
#}],
#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)

```

에이전트 상태 관리

대화 기록과 도구 결과를 유지 관리하여 컨텍스트를 보존합니다. 아래 예제에서는 싱글턴에서 이를 보여주지만 개발자는 워크플로 요구 사항에 따라 전체 에이전트 시스템을 오케스트레이션하는 방법을 결정할 수 있습니다. 또한 Strands와 같은 Amazon Web Services 도구는 개발자를 대신하여 에이전트 컨텍스트 및 도구 상태를 관리합니다.

```

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
```

#)

에이전트 모범 사례

에이전트 모범 사례에 대한 자세한 내용은 [the section called “모범 사례”](#) 섹션을 참조하세요.

대화형 AI 에이전트 개발에 대한 지침은 [음성-음성](#) 섹션을 참조하세요.

Web Grounding

웹 그라운드링을 사용하면 Amazon Nova가 웹에서 현재 정보를 검색하고 인용과 함께 응답을 제공할 수 있습니다. 이 기능은 모델의 훈련 데이터 외에 최신 정보가 필요한 쿼리에 유용합니다.

Web Grounding 작동 방식

프롬프트에 대해 Web Grounding이 활성화되면 다음 단계가 수행됩니다.

1. 요청 구성 - 애플리케이션에서 nova_grounding을 systemTool로 활성화한 상태로 Amazon Bedrock API에 사용자 프롬프트를 전송합니다.
2. 검색 및 분석: 모델은 검색이 필요한지를 결정하고, 관련 정보를 하나 이상 검색하며, 이해를 넓히거나 특정 하위 주제를 자세히 알아보기 위해 추가 검색이 필요한지 평가합니다.
3. 응답 생성 - Amazon Nova가 검색 결과의 정보를 자동으로 합성하여 실시간 정보에 근거한 최종 API 응답을 생성하며, 여기에는 출처에 대한 인용도 포함됩니다.

Web Grounding 사용 방법

웹 그라운드링을 활용하는 코드의 전체 예제는 코드 샘플 섹션을 참조하세요.

결과에 웹 그라운드링을 포함하려면 toolConfig 블록에 다음 systemTool 파라미터를 지정합니다.

```
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)
```

리전별 가용성

웹 그라운드링은 현재 미국 리전에서만 사용할 수 있으며 미국 CRIS 프로필에서만 지원됩니다.

응답 구조

다음은 응답의 예입니다. 간결성을 위해 응답을 축약했습니다.

```
{
```



```

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

```

각 인용에는 다음이 포함됩니다.

- **text**: 모델이 생성한 응답의 세그먼트입니다.
- **citationsContent**: 세그먼트와 관련된 인용 데이터의 기본 컨테이너입니다.
- **citations**: 인용의 위치가 담긴 citationsContent 내의 컨테이너입니다.
- **location**: 인용의 출처가 담긴 citations 내의 컨테이너입니다.
- **web**: 웹 소스 세부 정보가 담긴 location 내의 컨테이너입니다.
- **url**: 인용 출처의 전체 웹 주소(URL)입니다.
- **domain**: 출처 url의 루트 도메인입니다.

그라운드링 안전

데이터는 AWS 인프라를 벗어나지 않습니다. 모델 생성 쿼리는 AWS 서비스 내에 유지되며 더 광범위한 인터넷으로 전송되지 않습니다. 광범위한 내부 웹 검색 인덱스 및 지식 그래프는 신뢰할 수 있는 고품질 소스의 우선순위를 지정하고 수신 시 악성 콘텐츠를 필터링합니다. 마지막으로 런타임 필터링을 통해 간접 프롬프트 인젝션과 잘못된 정보로부터 애플리케이션을 보호합니다. 영어 이외의 언어의 경우 이 완화 조치가 제한됩니다.

오류 처리

이름이 nova_grounding인 toolSpec 항목을 포함하지 마세요. 이 이름의 도구를 포함하면 오류가 발생합니다.

다음은 Web Grounding을 사용할 때 발생할 수 있는 잠재적 오류 목록입니다.

- malformed_tool_use
- max_tokens
- malformed_model_output

기본 제공 도구에 필요한 권한

Amazon Bedrock에서 웹 그라운드링에 액세스할 수 있게 하려는 경우 두 가지 옵션이 있습니다:

1. IAM 역할에서 BedrockFullAccess 활성화: 역할에 BedrockFullAccess가 있는 경우 웹 그라운드링에 자동으로 액세스할 수 있습니다.
2. 특정 권한 추가(필요한 경우): 더욱 세부적인 액세스 제어가 필요한 경우 역할의 IAM 정책에 이 정책을 추가하고 계정 ID를 AWS 계정 계정 ID로 바꿉니다.

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

웹 그라운드링에서 aws:requestedRegion 조건 키는 'unspecified'로 설정되어 있습니다. 기존 정책이나 서비스 제어 정책(SCP)에서 이 조건을 적용하는 경우 액세스 문제가 발생할 수 있습니다. 'unspecified' requestedRegion을 허용하도록 조건을 업데이트하여 이 문제를 해결할 수 있습니다.

 Note

Web Grounding 도구를 활성화하는 경우 근거 정보를 포함하는 출력의 사용에 대한 책임은 사용자에게 있습니다. 최종 사용자에게 의한 사용에 대한 책임도 사용자에게 있습니다. 출력에 인용이나 출처 자료 링크의 근거 정보가 포함되는 경우 이를 알 수 있습니다. 최종 사용자에게 제공하는 출력에 이러한 인용 및 링크를 유지하고 표시해야 합니다.

 Note

Web Grounding은 추가 비용이 발생합니다. 자세한 내용은 [AWS Bedrock 요금](#)을 참조하세요.

프롬프트 엔지니어링 지침

프롬프트 엔지니어링은 Amazon Nova와 같은 대규모 언어 모델(LLM)과 효과적으로 통신하기 위한 지침을 설계하는 사례입니다. 프롬프트 엔지니어링을 사용하면 모델 동작을 제어하고, 출력 품질을 개선하며, 신뢰할 수 있는 AI 기반 애플리케이션을 빌드할 수 있습니다.

효과적인 프롬프트 엔지니어링에는 원하는 출력을 생성하도록 모델을 안내하는 입력 생성이 포함됩니다. 잘 만들어진 프롬프트는 명확한 지침, 관련 컨텍스트 및 적절한 형식의 입력 데이터를 제공합니다.

프롬프트 엔지니어링이란 무엇인가요?

프롬프트 엔지니어링이란 대규모 언어 모델(LLM)에 대한 텍스트 입력을 최적화하여 출력을 개선하고 원하는 응답을 받는 방법을 말합니다. 프롬프팅은 LLM이 분류, 질문 응답, 코드 생성, 창의적인 글쓰기 등을 비롯하여 다양한 태스크를 수행하는 데 도움이 됩니다. LLM에 제공하는 프롬프트의 품질은 모델의 응답 품질에 영향을 미칠 수 있습니다. 이 섹션에서는 프롬프트 엔지니어링을 시작하는 데 필요한 정보를 제공합니다. 그리고 Amazon Bedrock에서 LLM을 사용할 경우 사용 사례에 가장 적합한 프롬프트 형식을 찾는 데 도움이 되는 도구도 다룹니다.

프롬프트의 효과는 제공된 정보의 품질과 프롬프트 자체의 특징에 따라 달라집니다. 프롬프트에는 모델을 효과적으로 안내하고 결과의 품질을 개선하기 위한 지침, 질문, 컨텍스트 세부 정보, 입력 및 예제가 포함될 수 있습니다. 이 문서에서는 Amazon Nova 2 Sonic 모델 제품군의 성능을 최적화하기 위한 전략과 기술을 간략하게 설명합니다. 여기에 제시된 방법은 효과를 높이기 위해 다양한 조합으로 사용할 수 있습니다. 사용자가 직접 실험에 참여하여 자신의 특정 요구에 가장 적합한 접근 방식을 찾아볼 것을 권장합니다.

프롬프트 엔지니어링 시작하기

프롬프트 엔지니어링을 시작하기 전에 다음 요소를 준비하여 사용 사례에 가장 적합한 프롬프트를 반복적으로 개발할 수 있도록 하는 것이 좋습니다.

사용 사례 정의

4개의 차원에서 사용 사례를 정의합니다.

- **태스크** - 모델에서 수행하려는 태스크를 정의합니다. 이는 올바른 프롬프트 기법을 결정합니다.
- **역할** - 해당 태스크를 수행하기 위해 모델이 수임해야 하는 역할을 정의합니다. Amazon Nova 모델은 세 가지 역할(시스템, 사용자 또는 어시스턴트)을 지원합니다.
- **응답 스타일** - JSON, 마크다운 또는 대화와 같은 오디언스에 따라 모델이 따라야 하는 응답 구조 또는 스타일을 정의합니다.

- 지침 - 모델이 성공 기준을 충족하기 위해 따라야 할 일련의 지침을 정의합니다.

성공 기준 설정

성공 기준 또는 평가 지표를 정의합니다. 기준 목록을 제공하거나 길이, BLEU 점수, ROUGE, 형식, 사실성 및 충실도와 같은 특정 평가 지표를 제공할 수 있습니다.

프롬프트 초안 작성

태스크, 역할, 응답 스타일 및 지침을 통합하는 시작 프롬프트를 생성합니다. 결과를 기반으로 반복합니다.

프롬프트의 효과는 제공하는 정보의 품질에 따라 달라집니다.

일반 모범 사례

다음 모범 사례는 주로 Amazon Nova 텍스트 모델에 적용되지만, 양식별 모범 사례 외에도 다른 모델에 적용할 수 있습니다.

멀티모달 입력에서 프롬프트를 작성하는 방법에 대한 자세한 내용은 [멀티모달 입력 프롬프트](#) 섹션을 참조하세요. 음성 입력에서 프롬프트를 작성하는 방법에 대한 자세한 내용은 [음성 대화 프롬프트](#) 섹션을 참조하세요.

역할 이해

Amazon Nova 모델을 사용하면 시스템, 사용자, 어시스턴트의 세 가지 역할을 통해 프롬프트를 구성할 수 있습니다.

- 시스템(선택 사항) - 필수는 아니지만 어시스턴트의 전반적인 동작 파라미터를 설정합니다. 사용자가 대화 전반에 걸쳐 모델이 준수해야 할 추가 지침과 가이드라인을 제공하는 데 활용할 수도 있습니다.
- 사용자 - 사용자 쿼리와 함께 컨텍스트, 태스크, 지침 및 원하는 결과를 선택적으로 전달할 수 있습니다.
- 어시스턴트 - 모델을 의도한 응답으로 안내하는 데 도움이 됩니다.

주제

- [정확한 프롬프트 생성](#)
- [프롬프트의 섹션에 초점 맞추기](#)
- [시스템 역할 사용](#)

- [예제 제공\(퓨샷 프롬프팅\)](#)
- [도구 직접 호출 시스템](#)
- [고급 프롬프트 기법](#)

정확한 프롬프트 생성

프롬프트 엔지니어링에서는 구체적인 사용자 쿼리를 작성하는 것이 매우 중요합니다. 잘 작성된 쿼리는 Amazon Nova 텍스트 이해 모델이 정확하고 적절한 응답을 생성하도록 지시합니다. 이러한 쿼리를 작성하려면 먼저 쿼리에 맥락에 맞는 정보를 제공해야 합니다. 제공된 컨텍스트는 명확한 대상 사용자 시나리오에 맞춰 모델을 더 잘 배치하여 결과의 관련성과 일관성을 향상시키는 데 도움이 됩니다.

맥락에 맞는 구체적인 정보 제공

모델은 지침이 명확하고 체계적이며 짧고 구체적일 때 가장 효과적입니다. 이 프롬프트 템플릿 지침은 사용자 프롬프트와 시스템 프롬프트 모두에 적용됩니다.

프롬프트 템플릿

```
# 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}"""
```

예: 구체적이고 맥락에 맞는 정보

다음은 구체적이고 맥락에 맞는 정보로 다시 작성된 프롬프트의 예제입니다. 맥락에 맞는 정보를 더 추가하면 모델이 원하는 행동에 대한 근거를 마련하는 데 도움이 됩니다.

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]

- **명확성:** 모델에 프롬프팅할 때는 기계가 아닌 사람이 이해할 수 있는 방식(예: JSON 스타일 목록)으로 가능한 한 명확하게 설명합니다.
- **구체성:** 모델에 태스크의 내용, 예상 결과물 및 모델이 원하는 방식으로 응답하는 데 도움이 되는 추가 컨텍스트에 대한 구체적인 지침을 제공합니다.

출력 형식 및 스타일 지정

Amazon Nova 2가 특정 요구 사항에 맞는 응답을 생성하도록 하려면 출력의 형식과 스타일을 지정할 수 있습니다. JSON으로만 응답을 생성하거나 응답 길이를 최대 단어 수, 요점 또는 단락으로 제한하려는 경우를 예로 들 수 있습니다. 이를 통해 Amazon Nova 2는 요구 사항을 더 잘 이해하고 더 관련성이 높고 구문 분석하기 쉬운 출력을 생성할 수 있습니다.

모델이 엄격하게 준수하도록 하려는 규칙을 강조하려면 ‘반드시 합니다’, ‘해서는 안 됩니다’와 같은 강력한 어구를 사용합니다. 예를 들어, 응답에 JSON 객체를 하나만 원하는 경우 ‘반드시 JSON 형식으로만 답합니다. 질문에 답변할 때 다른 형식을 사용해서는 안 됩니다.’라고 모델에 지시할 수 있습니다.

다음은 구체적이고 맥락에 맞는 정보로 다시 작성된 프롬프트의 몇 가지 예제입니다. 맥락에 맞는 정보를 더 추가하면 모델이 원하는 행동에 대한 근거를 마련하는 데 도움이 됩니다.

예제 1: 추가 세부 정보 제공

응답 형식에 대한 추가 세부 정보를 추가하면 모델이 원하는 결과를 달성하는 데 도움이 될 수 있습니다. 일반적으로 사용되는 다른 응답 형식에는 CSV, 마크다운, YAML 및 XML이 포함됩니다.

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
```

...

## 예제 2: 스타일 제약 조건 제공

이 경우 스타일 제약 조건이 있는 프롬프트는 따라야 할 제약 조건과 원하는 응답 형식에 대한 포괄적인 정보를 제공합니다. 응답에서 볼 수 있듯이 최적화된 프롬프트는 요청된 간결성과 글머리표 목록 구조에 더욱 잘 부합합니다.

### 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.

### 예제 3: 응답 형식 제한

여기서 응답 형식이 있는 프롬프트는 모델이 자세한 내용은 배제하고 카테고리 번호로만 응답하고 1~10으로 제한하도록 합니다.

#### 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

## 명확한 프롬프트 섹션 제공

초기 컨텍스트 외에도 구조화된 쿼리 형식은 언어 모델과의 상호 작용을 최적화하는 데 중요한 역할을 합니다. 입력의 개별 부분을 구분 기호로 구분하면 명확성이 보장되고 Amazon Nova 2 모델의 쿼리 구조 이해 능력이 향상됩니다. 또 다른 효과적인 방법은 번호가 매겨진 목록 또는 글머리 기호를 사용하는 것입니다. 이렇게 하면 태스크를 관리 가능한 단계로 나누고 수행해야 할 작업에 대한 명확한 개요를 제공하는 데 도움이 됩니다. 이 구조화된 접근 방식은 모호성을 줄이고 생성된 응답의 정확도를 개선하는 데 도움이 됩니다.

예: 섹션화된 프롬프트 생성

섹션화된 프롬프트 열에서는 섹션화되지 않은 프롬프트 열의 지침과 비교할 때 프롬프트가 더 명확하고 태스크, 컨텍스트, 요구 사항 등 다양한 개체에 대한 섹션이 구분되어 있는 것을 볼 수 있습니다.

## Unsectioned Prompt

User:

Write an article about climate change for high school students explaining basic concepts, current impacts, and individual actions to mitigate it. Make it informative and engaging with simple language, including statistics and real-world examples.

Assistant:

### Understanding Climate Change: What It Is, What It's Doing, and What You Can Do About It

#### Introduction

Climate change might sound like a big, complicated topic, but it's really about the way our planet's weather is changing over time. This change is mostly happening because humans are doing things that are making our Earth warmer. Let's break it down so you can understand what's going on and what you can do to help.

#### #### What Is Climate Change?

Climate change refers to long-term shifts in temperatures and weather patterns. These shifts may be natural, but since the 1800s, human activities have been the main driver of rapid climate change.

#### \*\*Key Concept: Greenhouse Gases\*\*

To understand this, we need to talk about greenhouse gases. These gases, like carbon dioxide (CO<sub>2</sub>), methane (CH<sub>4</sub>), and nitrous oxide (N<sub>2</sub>O), trap heat in our atmosphere. Without these gases, Earth would be too cold for most life forms. But when we burn fossil fuels (like coal, oil, and natural gas) and cut down forests, we release too much CO<sub>2</sub> and other greenhouse gases, trapping more heat and making the planet warmer.

#### #### Current Impacts of Climate Change

Let's look at some real-world examples to see how climate change is affecting our world today.

#### \*\*1. Rising Temperatures\*\*

Since the late 19th century, Earth's average surface temperature has risen about 2 degrees Fahrenheit (1 degree Celsius). Scientists predict that if we don't change our ways, it could rise by 3.6 to 4.3 degrees Fahrenheit (2 to 2.4 degrees Celsius) by the end of this century.

#### \*\*2. More Extreme Weather\*\*

Climate change is making extreme weather events more frequent and severe. For example:

- **Hurricanes:** In the U.S., hurricane seasons are getting longer and more destructive. In 2020, there were 30 named storms, the most ever recorded.
- **Droughts:** Parts of California have experienced some of the worst droughts in history, affecting agriculture and water supplies.

#### \*\*3. Melting Ice Caps and Rising Sea Levels\*\*

Glaciers and ice sheets are melting at alarming rates. This not only affects wildlife but also leads to rising sea levels. Since 1901, global sea levels have risen by about 8 inches (20 centimeters). By 2100, they could rise by another 1 to 4 feet (0.3 to 1.2 meters).

#### \*\*4. Ocean Acidification\*\*

As CO<sub>2</sub> levels rise, more of it is absorbed by the oceans, making them more acidic. This is particularly harmful to marine life, including coral reefs. Coral reefs are crucial for marine biodiversity but are now dying at an alarming rate.

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

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

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

Try to minimize waste by:

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

#### **\*\*2. Conserve Energy\*\***

Small changes can lead to big savings:

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

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

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

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

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

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

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

#### **#### Conclusion**

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

Let's start today and build a sustainable future!

## Sectioned Prompt

User:

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

Write an article

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

Topic: Climate Change  
Target Audience: High School Students  
Purpose: Educational Article

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

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

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

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

## Assistant:

### # Understanding Climate Change: A Guide for High School Students

#### ## Introduction

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

#### ## What is Climate Change?

**\*\*Climate change\*\*** refers to long-term changes in global temperatures and weather patterns. These changes are primarily caused by human activities, especially the burning of fossil fuels like coal, oil, and natural gas. When we burn these fuels, we release large amounts of greenhouse gases, such as carbon dioxide (CO<sub>2</sub>) and methane (CH<sub>4</sub>), into the atmosphere. These gases trap heat from the sun, causing the Earth's temperature to rise. This is often referred to as the **\*\*greenhouse effect\*\***.

#### ### Basic Concepts:

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

3. **Climate Change**: Refers to the broader set of changes in the Earth's climate system, including global warming.

## ## Current Impacts of Climate Change

### ### On Ecosystems:

1. **Melting Ice Caps and Glaciers**: The polar ice caps and glaciers are melting at an alarming rate. For example, the Arctic sea ice is shrinking, which affects polar bears and other Arctic animals.
2. **Rising Sea Levels**: As ice melts, sea levels rise. This can lead to the loss of coastal habitats and increased flooding in coastal areas.
3. **Changing Weather Patterns**: Climate change can lead to more frequent and severe weather events such as hurricanes, droughts, and heatwaves. For example, the 2020 Australian bushfires were more intense and lasted longer than usual due to climate change.

### ### On Human Populations:

1. **Health Issues**: Rising temperatures can lead to more heat-related illnesses and the spread of diseases like malaria and dengue fever.
2. **Food Security**: Changes in climate can affect crop yields, leading to food shortages. For example, droughts in Sub-Saharan Africa have caused significant food insecurity.
3. **Displacement**: Rising sea levels and extreme weather events can force people to leave their homes, becoming climate refugees. For instance, communities in Bangladesh are being displaced by rising sea levels.

## ## Actions You Can Take

Even though climate change is a massive issue, there are many actions you can take to help mitigate its effects. Here are some simple steps you can start with today:

1. **Reduce, Reuse, Recycle**: By reducing waste, reusing items, and recycling, you can decrease the amount of trash that ends up in landfills and reduce greenhouse gas emissions.

2. **\*\*Save Energy\*\***: Turn off lights when you don't need them, use energy-efficient appliances, and unplug devices when they're not in use. These small actions can make a big difference.
3. **\*\*Use Less Meat\*\***: Livestock farming produces a significant amount of methane. By eating less meat, particularly beef, you can reduce your carbon footprint.
4. **\*\*Support Renewable Energy\*\***: Advocate for or invest in renewable energy sources like solar and wind power. These sources produce energy without greenhouse gas emissions.
5. **\*\*Educate and Advocate\*\***: Inform others about the impacts of climate change and advocate for policies that support environmental sustainability. You can join or support environmental clubs at school or participate in local clean-up efforts.

## ## Conclusion

Climate change is a complex issue with far-reaching impacts. However, understanding it and taking action can make a significant difference. By learning about the basic concepts, recognizing the current impacts, and implementing simple changes in our daily lives, we can all contribute to mitigating climate change. Remember, every small action counts, and together, we can create a more sustainable future for our planet.

## 프롬프트의 섹션에 초점 맞추기

Amazon Nova 2 모델은 섹션별로 지침을 구성한 다음 해당 섹션을 참조하여 프롬프트의 특정 부분에 주의를 기울일 수 있습니다. 마크다운, XML 또는 기타 구조를 사용하여 프롬프트에 명확한 섹션 구분이 있는 경우 모델은 주의를 기울일 수 있습니다. 예를 들어, 섹션 이름을 정의하고 `##Section Name##`을 사용한 다음 프롬프트에서 `##Section Name##`을 사용하여 해당 섹션을 참조할 수 있습니다.

또한 이 전략을 활용하여 모델이 생성된 응답에서 입력 프롬프트의 일부를 공개하지 못하도록 제한할 수 있습니다. 예를 들어 입력 프롬프트에 퓨샷 예제나 지침을 제공할 때 `##Instructions##` 또는 `##Examples##`와 같은 구분 기호와 새 줄 바꿈 기호를 사용하고 `DO NOT mention anything inside the ##Instructions## or ##Examples## in the response`와 같은 강력한 지침을 제공하여 모델이 이 섹션의 입력 프롬프트 콘텐츠를 출력에서 그대로 반복하지 않도록 합니다.

예: 섹션 구분

사용자:



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##`

## 시스템 역할 사용

시스템 역할은 애플리케이션의 최종 사용자에게 모델이 어떻게 응답할지 정의하는 지침을 모델에 제공할 수 있는 역할입니다. 예를 들어 시스템 역할은 모델이 주어진 페르소나로 응답하도록 안내하고, 허용되는 콘텐츠와 허용되지 않는 콘텐츠를 설정하고, 특정 형식으로 출력하고, 가드레일을 지정하는 등의 작업을 수행할 수 있습니다. 시스템 프롬프트라고 하는 시스템 역할의 지침은 개별 사용자 프롬프트에서 제공하는 다른 지침을 대체하며 모든 사용자 턴에 적용됩니다.

### API로 시스템 역할 지정

모델에 사용자 지정 역할을 부여하려면 다음과 같이 API에서 `system` 파라미터를 설정할 수 있습니다.

```
{
 "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

- 시스템 역할을 최대한 활용하려면 [정확한 프롬프트 생성](#)에 설명된 것과 동일한 전략에 따라 시스템 프롬프트가 명확하고 간결하며 구체적이어야 합니다. 예를 들어 모델이 응답해야 하는 주제를 제한하려면 ‘...에 대해 이야기해서는 안 됩니다.’ 또는 ‘반드시 ...에 대해 이야기합니다.’와 같이 구체적으로 지시하세요.
- 모델을 계층 구조로 더욱 제한하려면 시스템 프롬프트에 다음 접미사를 추가하여 시스템과 사용자 지침 간의 계층 준수 구조를 강조할 수 있습니다.

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

다음은 시스템 프롬프트 템플릿에 추가할 수 있는 몇 가지 항목입니다.

```
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}
"""

```

시스템 프롬프트에 시스템과 사용자 지침 간의 계층 준수 구조를 제공하려면 다음을 추가할 수 있습니다.

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.

### 예제 1: 특정 언어 신호 제공

시스템 프롬프트를 추가한 후 모델 응답은 시스템 프롬프트에 표시된 대로 중세 스크롤 스타일로 매우 양식화되었습니다.

### Without a System Prompt

시스템:

NA

사용자:

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

어시스턴트:

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

### 시스템:

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

### 사용자:

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

### 어시스턴트:

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.

## 예제 2: 가드레일 제공

시스템 프롬프트를 추가하면 사용자는 애플리케이션에 가드레일을 추가하여 의도하지 않은 사용으로부터 애플리케이션을 보호할 수 있습니다. 다음은 가드레일이 원하는 태스크에 모델을 집중할 수 있는 방법에 관한 예제입니다.

### Without a System Prompt

시스템:

NA

사용자:

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.)

## 어시스턴트:

### **\*\*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

### 시스템:

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

### 사용자:

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.)

## 어시스턴트:

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.

## 예제 제공(퓨샷 프롬프팅)

프롬프트에 태스크의 몇 가지 예제를 포함하면 Amazon Nova 2가 따를 수 있는 구조화된 템플릿을 만들 수 있습니다. 이렇게 하면 모호성이 줄어들고 출력의 정확도와 품질이 향상됩니다. 모델의 응답이 원하는 결과에 더 잘 부합하도록 명확한 예제를 제공하는 기술을 퓨샷 프롬프팅이라고 합니다.

퓨샷 프롬프팅의 개념은 입력 및 출력 형식과 함께 태스크의 몇 가지 예제를 언어 모델에 제공한 다음 제공된 예제를 기반으로 새 입력에 대한 출력을 생성하도록 요청하는 것입니다. 또한 이 방법은 복잡한 지침이나 태스크를 명확히 하여 Amazon Nova 2가 요청 내용을 더 쉽게 이해하고 해석할 수 있도록 합니다.

프롬프트에 예제를 추가하는 방법:

예제를 추가하면 모델이 다음을 수행하는 데 도움이 될 수 있습니다.

- 예제의 스타일과 일치하는 일관된 응답 생성
- 지침을 잘못 해석할 가능성을 줄이고 할루시네이션을 최소화하여 효과적인 응답 제공

퓨샷 프롬프팅을 사용하여 모델 성능이 얼마나 향상되는지는 선택한 예제의 품질과 다양성에 따라 달라집니다. 다음 항목은 프롬프트에서 좋은 샷의 특징을 보여줍니다.

- 다양한 예제 선택: 선택한 예제는 관련 사용 사례를 적절히 포괄할 수 있도록 다양성(일반적인 사용 사례부터 엷지 사례까지) 측면에서 예상되는 입력/출력 분포를 나타내야 합니다. 입력의 편향으로 인해 출력도 편향될 수 있으므로 예제에서 편향을 방지하는 것이 중요합니다.
- 복잡성 수준 일치: 제공된 예제의 복잡성은 대상 태스크 또는 시나리오와 일치해야 합니다. 프롬프트에서 예상 입력과 선택한 예제 사이에 복잡성 등급이 매핑되었는지 확인하는 것이 중요합니다.
- 관련성 확인: 선택한 예제는 현재 문제 또는 목표와 직접 관련이 있어야 합니다. 이렇게 하면 응답의 일관성과 균일성이 보장됩니다.

**i** Tip

위의 제안이 효과가 없다면 사용자 입력 쿼리와 사용 가능한 샷 풀 간의 유사성을 기반으로 동적 샷 선택으로 프롬프트를 보강하는 RAG 기반 시스템을 구축하는 것이 좋습니다.

## 예제 1: 사용자 프롬프트에 예제 제공

여기에서는 사용자가 들어오는 고객 지원 티켓을 미리 정의된 카테고리 분류하려고 합니다. Amazon Nova 2 모델에 올바르게 분류된 티켓의 몇 가지 예제를 제공하여 티켓에 사용되는 카테고리 언어에 대한 이해를 높일 수 있습니다. 예시 예제는 간결해야 하며 애플리케이션에서 목표로 하는 모든 태스크를 표현해야 합니다. 이 예의 Ticket이나 Category와 같이 태스크에 의미 있는 특정 필드 이름이 있는 경우에는 콜론 ":"을 바로 뒤에 붙여 해당 필드를 사용할 수 있습니다.

## 0-shot prompt

사용자:

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."

어시스턴트:

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

사용자:

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."

어시스턴트:

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.

## 예제 2: 턴 프롬프트로 예제 제공

이 예제에서는 예시가 예시당 한 차례씩 턴으로 제공되며, User 역할에는 입력이, Assistant 역할에는 해당 예제에 대한 예상 출력이 포함되어 있습니다.

### 0-shot Prompt

시스템:

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

Categories:

- Food
- Entertainment
- Health
- Wealth
- Other

사용자:

I have 20\$ in my pocket.

어시스턴트:

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)

시스템:

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

Categories:

- Food
- Entertainment
- Health
- Wealth
- Other

사용자:

I love to eat pizza.

어시스턴트:

Food

사용자:

I enjoy watching movies.

어시스턴트:

Entertainment

사용자:

I am going to the gym after this.

어시스턴트:

Health

사용자:

I have 20\$ in my pocket.

어시스턴트:

Wealth

### 예제 3: 시스템 프롬프트에 예제 제공

이 예에서는 '예제' 섹션을 지정한 다음 시스템 프롬프트에 일련의 예제를 나열할 수 있습니다. 프롬프트에 예시를 제공하는 이 방법은 예시가 길고 복잡한 경우 특히 유용하며 모델이 예제 샷을 찾는 데 도움이 됩니다.

#### 0-shot Prompt

시스템:

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.

사용자:

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

## 어시스턴트:

### # 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

시스템:

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]

사용자:

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

어시스턴트:

**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.

## 도구 직접 호출 시스템

도구 직접 호출은 요청에 도구 구성 스키마를 전달하여 Amazon Nova 모델에 사용할 수 있습니다. 모델에 대한 프롬프트는 이 도구 구성으로 보강되므로 도구 직접 호출 시스템 최적화를 시작하는 데 매우 큰 영향을 미칠 수 있습니다.

다음 주요 원칙을 고려하세요.

- 도구 정의는 명확하고 간결해야 합니다. 이해하기 쉽고 의도가 매우 명확해야 합니다.
- 주요 차별화 요소와 경계 조건을 사용하여 어떤 도구를 다른 도구보다 먼저 사용해야 하는지 정의합니다.
- 입력 인수 유형을 신중하게 선택합니다. 이것이 말이 되는지, 그리고 일반적으로 이런 방식으로 사용될 것으로 기대되는지 물어보세요.

‘도구 선택’을 사용하여 도구 직접 호출 시기 제어

도구 선택 파라미터를 사용하면 모델에서 도구 직접 호출의 동작을 사용자 지정할 수 있습니다. 어떤 도구가 언제 직접적으로 호출되는지 세밀하게 제어하려면 이 기능을 활용하는 것이 좋습니다.

예를 들어 구조화된 출력과 같은 사용 사례의 경우 Amazon Nova가 간접적으로 호출될 때마다 특정 도구를 직접적으로 호출할 수 있습니다. 출력의 스키마를 도구로 정의한 다음 도구 선택을 해당 도구의 이름으로 설정할 수 있습니다.

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

많은 에이전트 사용 사례의 경우 모델이 항상 사용 가능한 도구 중 하나를 선택하도록 해야 할 수 있습니다. 이렇게 하려면 도구 선택을 any로 설정하면 모델이 간접적으로 호출될 때마다 정확히 하나의 도구가 직접적으로 호출됩니다.

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

```
}
}
```

마지막으로, 도구 직접 호출 여부가 대화의 맥락에 따라 크게 좌우되는 사용 사례의 경우 도구 선택을 auto로 설정할 수 있습니다. 이는 기본 동작이며 도구 선택을 전적으로 모델에 맡깁니다.

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

## 고급 프롬프트 기법

이 섹션에서는 프롬프트의 품질을 개선하고 확장된 사고와 같은 주요 기능을 활용하는 방법에 대한 고급 지침을 제공합니다.

### 추론 모드 사용

Amazon Nova 2 모델은 응답하기 전에 문제를 체계적으로 해결할 수 있도록 지원함으로써 복잡한 문제 해결에 대한 모델의 접근 방식을 개선하는 선택적 추론 모드를 제공합니다. 모델의 추론 모드 활용은 프롬프트의 정확도를 개선하는 강력한 방법입니다.

사용 시점: 추론 모드는 다음 사용 사례와 같이 복잡한 태스크에 대해 권장됩니다.

- 여러 추론 단계: 수학적 증명, 알고리즘 설계, 시스템 아키텍처
- 교차 참조 정보: 문서 분석, 옵션 비교, 장단점 평가
- 오류가 발생하기 쉬운 계산: 재무 모델링, 데이터 분석, 복잡한 디버깅
- 제약 조건을 포함하는 계획: 리소스 최적화, 종속성 관리, 위험 평가
- 복잡한 분류: 다중 레이블 분류, 계층적 분류, 미묘한 의사 결정 경계
- 도구 직접 호출 시나리오: 여러 단계의 API 워크플로, 데이터베이스 쿼리 최적화, 조정된 시스템 통합

#### Note

추론 모드에 대한 자세한 내용은 [추론 사용](#) 섹션을 참조하세요.

## 하향식 접근 방식 채택

모델이 문제를 해결하기 위해 여러 접근 방식을 평가해야 하는 상황에서 하향식 접근 방식을 채택하도록 지시합니다.

- Amazon Nova 2 모델은 모델이 전체적 상황 파악부터 시작한 다음 이를 더 작고 세부적인 하위 문제 또는 단계로 나눌 때 더 나은 성능을 발휘합니다.
- 모델이 먼저 주요 목표를 식별한 다음 이를 관리 가능한 구성 요소로 분해한 후 각 부분의 세부 정보를 살피도록 명시적으로 지시합니다.
- 이 구조화된 접근 방식은 모델이 사고를 구성하고 보다 일관된 추론 체인을 생성하는 데 도움이 됩니다.

예시:

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

## 연쇄적 사고 조정

추론 모드는 체계적인 문제 해결을 통해 향상된 정확도를 제공하지만, 비추론 모드에서의 연쇄적 사고 (CoT) 프롬프트가 요구 사항을 더 잘 충족할 수 있는 특정 시나리오가 있습니다.

이 기능을 사용해야 하는 경우:

- 투명성 및 감사 가능성: 모델의 추론 프로세스를 참조, 확인 또는 감사하려는 경우 CoT는 각 단계에 대한 전체 가시성을 제공합니다. 이는 규제 대상 산업, 고위험 의사 결정 또는 답변 뒤에서 로직을 문서화하려는 경우에 매우 중요합니다.
- 사용자 지정 추론 구조: CoT를 사용하여 특정 추론 패턴 또는 방법론을 적용합니다. 조직의 의사 결정 프레임워크를 따르거나 도메인별 문제 해결 접근 방식을 사용하거나 요소를 특정 순서로 고려하도록 모델을 안내할 수 있습니다.
- 프롬프트 개발 및 디버깅: 프롬프트 엔지니어링 단계에서 CoT는 모델이 문제에 접근하는 방식을 이해하고 추론이 중단되는 위치를 식별하며 프롬프트를 더 효과적으로 반복하는 데 도움이 됩니다.
- 하이브리드 접근 방식: 개발 중에 CoT를 사용하여 프롬프트를 완성한 다음, 특정 사용 사례에 대한 모델의 접근 방식에 자신이 있으면 프로덕션 배포를 위한 추론 모드로 전환하는 방법을 고려합니다.

**Note**

모든 태스크에 CoT가 필요한 것은 아닙니다. 더 간단한 태스크의 경우 모델에서 자체 추론 프로세스를 사용하도록 허용합니다.

**모델의 CoT 방향 안내**

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

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

**긴 컨텍스트 기간 활용**

Amazon Nova 2 모델에서 지원되는 컨텍스트 길이는 1백만 개의 토큰이며 긴 문서에서 코드 이해 및 질문 답변에 뛰어납니다. 컨텍스트 크기가 증가함에 따라 성능(시스템 프롬프트 준수 및 도구 사용 포함)이 약간 저하될 수 있습니다.

이 기능을 사용하는 방법:

- 긴 형식 데이터를 시작 부분에 배치: 긴 문서와 입력을 프롬프트 시작 부분에 배치합니다. 쿼리, 지침 및 예제 앞에 배치합니다.
- 끝에 지침 배치: 프롬프트 끝에 지침을 배치합니다. 모델은 컨텍스트가 먼저 제공되고 지침이 끝에 제공될 때 가장 성능이 좋습니다.
- 문서 콘텐츠 시작 및 종료 마커 구조화: DOCUMENT {idx} START 및 DOCUMENT {idx} END와 같은 시작 및 종료 마커를 사용하여 긴 문서의 시작과 끝을 나타냅니다. 여기서 {idx}는 특정 문서의 인덱스를 나타냅니다.

템플릿 예제:

```
// 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
```

## 지원 텍스트의 그라운드링 답변

모델에 입력 쿼리와 관련된 신뢰할 수 있는 정보를 제공하는 것이 좋습니다. 이 정보는 종종 입력 쿼리와 함께 검색 증강 생성(RAG)이라는 시스템에 포함됩니다.

- 이 과정에서 일부 관련성 있고 맥락에 맞는 문서 또는 정보가 실제 사용자 프롬프트에 보강되어 모델이 신뢰할 수 있는 콘텐츠를 확보하여 관련성 있고 정확한 응답을 생성합니다.
- Amazon Nova 2에 신뢰할 수 있는 출처의 참조 텍스트를 사용하여 답변하도록 지시하면 제공된 자료를 기반으로 답변을 작성하도록 안내하고 정확하고 관련성 있는 정보를 기반으로 답변을 작성하여 생성된 콘텐츠의 신뢰성과 신뢰도를 높일 수 있습니다.
- 참조 텍스트를 사용하면 할루시네이션을 피할 수 있어 응답의 전반적인 품질과 신뢰성이 향상됩니다. 할루시네이션을 최소화하려면 모델 지침에 DO NOT USE INFORMATION THAT IS NOT IN REFERENCE TEXTS!를 명시적으로 언급하는 것이 좋습니다.

## 프롬프트 템플릿

```
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}
```

예제: 그라운드링 컨텍스트를 제공하면 모델이 할루시네이션을 방지하는 데 도움이 됩니다.

이 예제에서는 그라운드링 컨텍스트를 통해 모델에서 할루시네이션을 방지하는 방법을 보여줍니다.



## 시스템:

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!

## 사용자:

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.

## 인용 마커를 사용하는 그라운드링

긴 문서 태스크의 경우 Amazon Nova 2 모델이 태스크를 진행하기 전에 문서의 관련 섹션의 인용을 사용하여 응답을 근거하도록 지시하는 것이 좋습니다.

이 접근 방식은 모델이 가장 관련성이 높은 정보에 집중하고 불필요한 콘텐츠로 인해 산만해지는 것을 방지하는 데 도움이 됩니다. 모델에 응답을 그라운드링하도록 요청할 때 인용할 수 있는 섹션에 숫자가 지정되어야 합니다. 예: Passage %[1]%, Passage %[2]% 등.

예제: 인용 마커 사용

## Example인용 마커 프롬프트

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)

...

사용자의 태스크를 기반으로 주요 정보를 추출한 후, 추출된 재무 지표를 사용하여 다음과 같이 관련 질문에 답변할 수 있습니다.

**Example추출된 지표를 사용한 후속 분석****## 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

## Nova 웹 그라운드링 사용

Amazon Nova 2 모델은 지원 텍스트에 모델을 그라운드링하도록 인용을 직접 프롬프트로 작성하는 대신, 사용 가능한 내부 웹 그라운드링 도구를 제공합니다. 이 기능이 활성화되면 Amazon Nova 2 모델은 웹 및 Amazon의 지식 그래프를 직접 쿼리하고 인용을 사용하여 최종 응답을 그라운드링합니다.

Amazon Nova Web Grounding을 활용하는 방법에 대해 자세히 알아보려면 [Amazon Nova Web Grounding 사용 설명서](#)를 참조하세요.

## 구조화된 출력 생성

일관되고 구조화된 출력 형식을 보장하기 위해 XML, JSON, 마크다운과 같은 형식을 비롯해 구조화된 출력을 사용하거나 도구 사용 기능을 사용할 수 있습니다.

- 이 접근 방식을 사용하면 다운스트림 시스템에서 모델에 의해 생성된 출력을 보다 효과적으로 이해하고 구문 분석할 수 있습니다.
- 모델에 명시적 지침을 제공하면 미리 정의된 스키마를 준수하는 방식으로 응답이 생성됩니다.

예를 들어 다운스트림 구문 분석기가 JSON 객체의 키에 대한 특정 명명 규칙을 예상하는 경우 프롬프트 끝에서 응답 스키마를 지정해야 합니다. 또한, 머리말 텍스트 없이 JSON 형식으로 응답을 받는 것을 선호하는 경우 모델에 그에 맞는 지시를 내리세요. 즉, 깨끗한 출력을 위해 명시적으로 다음과 같이 진술합니다. JSON 출력만 생성하세요. 프리앰블을 제공하지 마세요.

### Tip

- 예제(예: YYYY/MM/DD 형식으로 날짜 지정)를 사용하는 대신, 스키마 자체에 정의된 경우 데이터 형식 요구 사항을 가장 잘 준수하는 것으로 나타났습니다.

- 최대 10개의 키가 있는 단순한 JSON 출력의 경우 아래에서 스키마를 찾을 수 있습니다. 보다 복잡한 스키마의 경우 도구를 통해 스키마를 정의하는 것이 좋습니다. 도구 사용 시 이러한 복잡한 스키마에 대한 모델의 준수 정도를 높이는 제한된 디코딩이라는 기술을 활용합니다.

## 일반적인 형식 지정 스키마

다음은 몇 가지 일반적인 형식 지정 스키마에 대한 예제입니다.

### 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 )
```

```
"""
```

어시스턴트 콘텐츠 미리 채우기

비추론 모드에서 구조화된 출력을 생성하는 경우 어시스턴트 콘텐츠를 미리 채워 모델의 응답을 유도할 수 있습니다.

미리 채우는 방식은 비추론 모드인 동안 출력 형식의 일관성을 개선합니다. 이를 통해 사용하면 모델의 작업을 지시하고, 머리말을 우회하며, JSON 및 XML과 같은 특정 출력 형식을 적용할 수 있습니다. 예를 들어 어시스턴트 콘텐츠에 { 또는 ``json을 미리 채우면 추가 정보를 제공하지 않고도 모델이 JSON 객체를 생성하도록 안내할 수 있습니다.

Tip

명시적으로 JSON을 추출하려는 경우 일반적인 패턴은 ``json으로 미리 채우고 ``에 중지 시퀀스를 추가하는 것입니다. 이렇게 하면 모델이 프로그래밍 방식으로 구문 분석할 수 있는 JSON 객체를 출력합니다.

Example 어시스턴트 콘텐츠 미리 채우기

다음 코드는 API로 미리 채우는 방법을 보여줍니다.

```
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())
```

복잡한 스키마에 대해 사용할 도구 지정

또 다른 접근 방식은 도구 사용 스키마 섹션에 Pydantic JSON 스키마를 포함하여 모델 응답에 대한 특정 스키마를 강제로 적용하도록 도구를 사용하는 것입니다. 제공된 스키마에 도구 선택을 지정할 수 있으며 선택한 도구에 따라 Amazon Nova의 응답이 구성됩니다. 도구 활용 방법에 대해 자세히 알아보려면 [도구 사용](#)을 참조하세요.

예제

예제 1: 출력 스키마 추가

적절한 스키마로 출력 스키마 섹션을 추가하면 모델이 해당 스키마에 맞게 설정됩니다. 그러나 모델 출력은 결정적이지 않으며 출력 스키마와 다를 수 있습니다.

Unspecific Prompt

사용자:

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.

어시스턴트:

```
```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

### 사용자:

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"
}]
```

### 어시스턴트:

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

## 예제 2: 모델 응답 미리 채우기

또 다른 접근 방식은 어시스턴트의 메시지에 원하는 초기 텍스트를 포함하여 모델의 응답을 미리 채우는 것입니다. 이 경우 Amazon Nova 모델의 응답은 어시스턴트의 메시지가 중단된 지점부터 계속됩니다.

팁: 미리 채우기는 추론이 활성화되지 않은 경우에만 유효합니다.

사용자:

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.

어시스턴트(미리 채우기):

```
```json
```

어시스턴트:

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

```

예제 3: 사용할 도구 지정

구조화된 출력에 대해 미리 채우기 기술을 사용하는 대신 Nova의 도구 기능을 toolChoice와 결합할 수 있습니다. 이 예제에서 모델은 제공된 JSON 스키마를 준수하고 정의된 전체 JSON 형식으로 지정된 특정 도구를 직접 호출하는 도구 직접 호출을 생성합니다. 추가 지침은 고급 시스템을 참조하세요.

사용자:

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"
  }
}
}

```

다국어 사용 사례

Amazon Nova 2 모델은 200개가 넘는 언어에서 훈련되었으며 15개 언어에 대해 최적화되었습니다.

주제

- [정확한 번역을 위한 프롬프트](#)
- [일관된 쓰기 규칙 적용](#)

정확한 번역을 위한 프롬프트

짧은 양식 번역(몇 개의 문장)에 이 기능을 활용하려면 텍스트를 지정된 대상 언어로 번역하도록 모델에 지시할 수 있습니다.

Example번역 프롬프트

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}

일관된 쓰기 규칙 적용

문자 기반 언어에서 Amazon Nova 2 모델은 소스 언어의 문자 세트를 활용할 수 있습니다. 다음 프롬프트를 사용하여 일관된 출력을 적용할 수 있습니다.

Example쓰기 규칙 적용

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

도구 직접 호출

에이전트 시스템

주제

- [올바른 추론 파라미터 설정](#)
- [지연 시간 요구 사항 고려](#)
- [도구 직접 호출 지침에 대해 의도적인 문구 사용](#)
- ['사고' 명령 활용](#)
- [도구 직접 호출 순서 지정](#)
- [품질 도구 스키마 생성](#)
- [하위 에이전트 생성](#)
- [멀티모달 입력에 대해 도구 사용](#)
- [다음 단계](#)

올바른 추론 파라미터 설정

도구를 직접 호출하려면 모델의 매우 구체적인 구조화된 출력이 필요하며, 다음과 같은 추론 파라미터를 사용하여 개선됩니다.

- 비추론 모드: 온도: 0.7 및 상위 P: 0.9
- 추론 모드: 온도: 1 및 상위 P: 0.9

지연 시간 요구 사항 고려

Tip

Amazon Nova 2 모델은 추론을 켜거나 끈 상태에서 도구를 직접 호출할 수 있습니다. 그러나 추론 모드는 지연 시간에 상당한 영향을 미칩니다.

자연 시간에 민감한 애플리케이션의 경우 추론 꺼짐 모드에 맞게 최적화하고 가능한 경우 필요한 도구 직접 호출을 단순화해야 합니다. 여러 단계의 워크플로를 개별 단계로 분할하여 불필요한 파라미터의 재귀에 대한 모델의 의존도를 줄입니다.

도구 직접 호출 지침에 대해 의도적인 문구 사용

도구 이름: 시스템 프롬프트에서 도구를 참조하는 것은 도구를 직접 호출할 때 모델을 지시하는 도구 직접 호출 시스템에서 일반적입니다. 프롬프트에서 도구를 참조할 때는 xml 또는 pythonic 참조나 예제 대신 도구 이름을 사용하는 것이 좋습니다.

좋은 도구 참조에 대한 예제

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

잘못된 도구 참조에 대한 예제

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

'사고' 명령 활용

사고가 도구 직접 호출에 도움이 되는 모든 사용 사례의 경우 모델에 '태그 내 사고'를 유도하거나 '사고' 도구를 사용하라는 프롬프트를 작성하는 대신 추론 모드를 활용하는 것이 좋습니다.

Amazon Nova 2 모델은 추론 모드를 위해 광범위하게 훈련되었으며 연쇄적 사고를 위해 추론 모드에서 사용할 때 최적의 결과를 생성합니다.

도구 직접 호출 순서 지정

기본 제공 도구와 네이티브 도구 직접 호출을 동시에 사용해야 할 수 있는 사용 사례에서는 모델이 기본 제공 도구를 먼저 직접 호출하는 쪽을 택합니다.

프롬프트에서 다르게 작동하도록 모델에 지시하지 마세요. 대신 이를 고려하도록 워크플로를 설계합니다.

예를 들어 모델이 기본 제공 도구를 사용하지 않도록 하려면 모델이 해당 도구에 편향되지 않도록 워크플로에 포함하지 않습니다.

품질 도구 스키마 생성

도구 스키마는 엔지니어에게 효과적인 도구 직접 호출 시스템을 프롬프트할 수 있는 주요 위치 중 하나입니다. 그러나 도구 스키마 자체에서 캡처되는 내용, 각 스키마 요소의 시맨틱을 설명하는 방법, 시스템 프롬프트가 시스템 지침 내에서 도구 및 스키마 요소를 참조하는 방법을 고려하는 것이 중요합니다.

Amazon Nova 2 모델은 도구 스키마에서 간결한 설명에 최적화되어 있습니다. 짧게 유지하세요.

도구 스키마 및 시스템 프롬프트 지침 비교:

도구 스키마에 다음을 포함합니다.

- 핵심 기능: 도구가 수행하는 작업(20~50개 단어가 권장됨)
- 파라미터 사양: 각 파라미터에 대한 명확한 설명(파라미터당 약 10개의 단어)
- 예상 형식: 데이터 유형(예: 열거형, 정수, 부동 소수점), 필수 필드 및 유효한 값 범위

시스템 프롬프트에 다음을 포함합니다.

- 오케스트레이션 로직(특정 도구를 사용하는 시점과 이유) 및 비즈니스 규칙(조건부 로직, 시퀀싱 요구 사항 및 종속성)이 포함된 `#Tool Usage` 섹션을 지정합니다.
- 오류 처리 전략: 실패 또는 예상치 못한 출력에 응답하는 방법에 대한 지침이 포함된 `#Error Handling and Troubleshooting` 섹션 추가
- 출력 형식 지정: 사용자에게 제시하는 방법에 대한 세부 정보 추가

예제

```
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>
```

하위 에이전트 생성

다음과 같은 상황이 발생하면 많은 도구가 있는 단일 에이전트 대신 특수 하위 에이전트를 생성하는 방법을 고려합니다.

- 20개를 초과하는 도구 수: 큰 도구 세트는 관리하기 어렵고 선택 오류가 증가하는 경우
- 고유한 기능 도메인: 도구가 자연스럽게 별도의 카테고리(예: 데이터 검색, 처리, 보고)로 클러스터링 되는 경우
- 복잡한 스키마: 파라미터 깊이가 3~4 수준을 초과하거나 도구에 복잡한 상호 종속성이 있는 경우
- 대화 길이: 워크플로가 정기적으로 15~20회 턴을 초과하면 특수 하위 에이전트의 이점을 얻을 수 있는 경우
- 성능 저하: 도구 선택의 정확도 감소 또는 지연 시간 증가가 관찰되는 경우

Tip

MCP 서버는 사용자가 제어할 수 없는 도구 및 스키마와 함께 제공됩니다. 워크플로에서 필요한 태스크를 완료하는 데 필요한 도구만 포함합니다.

멀티모달 입력에 대해 도구 사용

멀티모달 태스크의 경우 구조화된 태스크(예: 추출 또는 타임스탬프 생성)를 위한 도구를 활용하는 정확도가 향상되지 않았습니다.

대신 제공된 템플릿을 사용하여 모델을 성공적으로 프롬프트하는 방법을 알아보려면 멀티모달 입력 프롬프트 섹션에서 관련 섹션을 검토하는 것이 좋습니다.

다음 단계

- 멀티모달 프롬프트는 [멀티모달 입력 프롬프트](#) 섹션을 참조하세요.

멀티모달 입력 프롬프트

다음 섹션에서는 이미지 및 비디오 이해에 관한 지침을 제공합니다. 오디오 관련 프롬프트는 [the section called “음성 대화 프롬프트”](#) 섹션을 참조하세요.

일반 멀티모달 지침

사용자 프롬프트 및 시스템 프롬프트

멀티모달 이해 사용 사례에서 모든 요청에는 사용자 프롬프트 텍스트가 포함되어야 합니다. 텍스트만 포함할 수 있는 시스템 프롬프트는 선택 사항입니다.

시스템 프롬프트를 사용하여 모델의 페르소나를 지정하고 일반적인 성격과 응답 스타일을 정의할 수 있지만, 자세한 태스크 정의나 출력 형식 지정 지침에 사용해서는 안 됩니다.

멀티모달 사용 사례에 대한 시스템 프롬프트보다 더 강력한 효과를 얻으려면 사용자 프롬프트에 태스크 정의, 지침 및 서식 세부 정보를 포함합니다.

콘텐츠 순서

Amazon Nova로 전송된 멀티모달 이해 요청에는 하나 이상의 파일과 하나의 사용자 프롬프트가 포함되어야 합니다. 사용자 텍스트 프롬프트는 메시지에서 항상 이미지, 문서 또는 비디오 콘텐츠 뒤의 마지막 항목이어야 합니다.

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

사용자 프롬프트 내에서 특정 파일을 참조하려는 경우 'text' 요소를 사용하여 각 파일 블록 앞에 있는 레이블을 정의합니다.

```
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>" }
  ]
}
```

문서 및 이미지 이해

다음 섹션에서는 이미지 및 문서를 이해하거나 분석해야 하는 태스크에서 프롬프트를 만드는 방법에 대한 지침을 제공합니다.

이미지에서 텍스트 추출

Amazon Nova 모델은 광학 문자 인식(OCR)이라고 하는 기능으로 이미지에서 텍스트를 추출할 수 있습니다. 최상의 결과를 얻으려면 텍스트 문자를 쉽게 식별할 수 있을 만큼 모델에 제공하는 이미지 입력의 해상도가 충분히 높은지 확인합니다.

텍스트 추출 사용 사례의 경우 다음 추론 구성을 사용하는 것이 좋습니다.

- temperature: 기본값(0.7)
- topP: 기본값(0.9)
- 추론을 활성화하지 않음

Amazon Nova 모델은 마크다운, HTML 또는 LaTeX 형식으로 텍스트를 추출할 수 있습니다. 다음과 같은 사용자 프롬프트 템플릿이 권장됩니다.

```
## 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.

출력은 전체 또는 부분 마크다운 코드 펜스(```)로 래핑됩니다. 다음과 유사한 코드를 사용하여 코드 펜스를 제거할 수 있습니다.

```
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()
```

이미지 또는 텍스트에서 구조화된 정보 추출

Amazon Nova 모델은 이미지에서 키 정보 추출(KIE)이라고 하는 프로세스를 통해 기계에서 구문 분석 가능한 JSON 형식으로 정보를 추출할 수 있습니다. KIE를 수행하려면 다음을 제공합니다.

- JSON 스키마. JSON 스키마 사양을 따르는 정식 스키마 정의입니다.
- 문서 파일, 이미지 또는 문서 텍스트 중 하나 이상

문서 또는 이미지는 요청에서 항상 사용자 프롬프트 앞에 배치해야 합니다.

KIE의 경우 다음 추론 구성을 사용하는 것이 좋습니다.

- temperature: 0
- 추론: 추론은 필요하지 않지만 이미지 전용 입력 또는 복잡한 스키마를 사용할 때 결과를 개선할 수 있습니다.

프롬프트 템플릿

문서 또는 이미지 전용 입력

```
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}
```

텍스트 전용 입력

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}
```

문서 또는 이미지 및 텍스트 입력

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}
```

이미지에서 객체 및 해당 위치 탐지

Amazon Nova 2 모델은 이미지 내에서 객체와 해당 위치를 식별하는 기능을 제공합니다. 이 태스크는 이미지 그라운드링 또는 객체 현지화라고도 합니다. 실제 애플리케이션에는 이미지 분석 및 태그 지정, 사용자 인터페이스 자동화, 이미지 편집 등이 포함됩니다.

이미지 입력 해상도 및 종횡비에 관계없이 모델은 이미지를 가로 1,000단위, 세로 1,000단위로 나누는 좌표 공간을 사용하며, x:0 y:0 위치는 이미지의 왼쪽 상단입니다.

경계 상자는 각각 왼쪽, 위쪽, 오른쪽 및 아래쪽을 나타내는 [x1, y1, x2, y2] 형식을 사용하여 설명됩니다. 2차원 좌표는 [x, y] 형식을 사용하여 표시됩니다.

객체 탐지 사용 사례의 경우 다음 추론 파라미터 값을 사용하는 것이 좋습니다.

- temperature: 0
- 추론을 활성화하지 않음

프롬프트 템플릿: 일반 객체 탐지

다음과 같은 사용자 프롬프트 템플릿을 권장합니다.

경계 상자를 사용하여 여러 인스턴스 탐지:

```
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.
```

경계 상자를 사용하여 단일 리전 탐지:

```
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.
```

중심점을 사용하여 여러 인스턴스 탐지:

```
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.

중심점을 사용하여 단일 리전 탄지:

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.

모델 출력 구문 분석:

위의 각 권장 프롬프트는 다음과 유사한 양식으로 하나 이상의 경계 상자 설명을 포함하는 쉼표로 구분된 문자열을 생성합니다. 문자열 끝에서 "."의 포함 여부는 조금씩 달라질 수 있습니다. 예: [356, 770, 393, 872], [626, 770, 659, 878].

다음 Python 코드 예제와 같이 정규식을 사용하여 모델에서 생성된 좌표 정보를 구문 분석할 수 있습니다.

코드 예제

```
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)
    ]
```

코드 예제

경계 상자의 정규화된 좌표를 입력 이미지의 좌표 공간에 다시 매핑하기 위해 다음 Python 예제와 유사한 함수를 사용할 수 있습니다.

```
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,
```

]

프롬프트 템플릿: 여러 위치를 사용하여 여러 객체 클래스 탐지

이미지에서 항목의 여러 클래스를 식별하려는 경우 다음 형식 지정 접근 방식 중 하나를 사용하여 프롬프트에 클래스 목록을 포함할 수 있습니다.

모델이 잘 이해할 수 있는 일반적으로 이해되는 클래스의 경우 대괄호 안에 클래스 이름(따옴표 제외)을 나열합니다.

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

미묘하거나 흔하지 않거나 모델이 익숙하지 않을 수 있는 특수 도메인에 속하는 클래스의 경우 괄호 안에 각 클래스에 대한 정의를 포함합니다. 이 태스크는 어렵기 때문에 모델의 성능이 저하될 것으로 예상됩니다.

```
[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)]
```

선호하는 JSON 출력 형식에 따라 다음 사용자 프롬프트 템플릿 중 하나를 사용합니다.

프롬프트 옵션 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]
  },
  ...
]
```



```
]
```

프롬프트 옵션 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]
  },
  ...
]
```

프롬프트 옵션 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], ...],
  ...
}
```

프롬프트 옵션 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], ...]
  },
  ...
]
```

모델 출력 구문 분석

출력은 JSON 구문 분석 라이브러리로 구문 분석할 수 있는 JSON으로 인코딩됩니다.

프롬프트 템플릿: 스크린샷 UI 경계 탐지

다음과 같은 사용자 프롬프트 템플릿을 권장합니다.

목표를 기반으로 UI 요소 위치 탐지:

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.

텍스트를 기반으로 UI 요소 위치 탐지:

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.

모델 출력 구문 분석:

위의 각 UI 경계 탐지 프롬프트에 대해 아래 Python 코드 예제와 같이 정규식을 사용하여 모델에서 생성된 좌표 정보를 구문 분석할 수 있습니다.

코드 예제

```
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)
]
```

비디오 이해

다음 섹션에서는 비디오를 이해하거나 분석해야 하는 태스크에서 프롬프트를 만드는 방법에 대한 지침을 제공합니다.

비디오 요약

Amazon Nova 모델은 비디오 콘텐츠 요약을 생성할 수 있습니다.

비디오 요약 사용 사례의 경우 다음 추론 파라미터 값을 사용하는 것이 좋습니다.

- temperature: 0
- 일부 사용 사례는 모델 추론을 활성화할 때 도움을 받을 수 있습니다.

특정 프롬프트 템플릿은 필요하지 않습니다. 사용자 프롬프트에서 관심 있는 비디오의 측면을 명확하게 지정해야 합니다. 다음은 효과적인 프롬프트에 대한 몇 가지 예제입니다.

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?

비디오에 대한 자세한 캡션 생성

Amazon Nova 모델은 비디오에 대한 자세한 캡션을 생성할 수 있습니다(이 태스크를 고밀도 캡션이라고도 함).

비디오 캡션 생성 사용 사례의 경우 다음 추론 파라미터 값을 사용하는 것이 좋습니다.

- temperature: 0
- 일부 사용 사례는 모델 추론을 활성화할 때 도움을 받을 수 있습니다.

특정 프롬프트 템플릿은 필요하지 않습니다. 사용자 프롬프트에서 관심 있는 비디오의 측면을 명확하게 지정해야 합니다. 다음은 효과적인 프롬프트에 대한 몇 가지 예제입니다.

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.

보안 비디오 영상 분석

Amazon Nova 모델은 보안 영상에서 이벤트를 탐지할 수 있습니다.

보안 영상 사용 사례의 경우 다음과 같은 추론 파라미터 값을 권장합니다.

- temperature: 0
- 일부 사용 사례는 모델 추론을 활성화할 때 도움을 받을 수 있습니다.

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.

타임스탬프를 사용하여 비디오 이벤트 추출

Amazon Nova 모델은 비디오에서 이벤트와 관련된 타임스탬프를 식별할 수 있습니다. 타임스탬프를 초 단위 또는 MM:SS 형식으로 지정하도록 요청할 수 있습니다. 예를 들어 비디오에서 1분 25초에 발생하는 이벤트는 85 또는 01:25로 표시할 수 있습니다.

이 사용 사례에서는 다음 추론 파라미터 값을 사용하는 것이 좋습니다.

- temperature: 0
- 추론을 사용하지 않음

다음과 비슷한 프롬프트를 사용하는 것이 좋습니다.

이벤트의 시작 및 종료 시간 식별

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]]

이벤트의 여러 발생 식별

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]]

타임스탬프가 있는 비디오 세그먼트 로그 생성

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.

비디오 분류

Amazon Nova 모델을 사용하여 사용자가 제공하는 미리 정의된 클래스 목록을 기반으로 비디오를 분류할 수 있습니다.

이 사용 사례에서는 다음 추론 파라미터 값을 사용하는 것이 좋습니다.

- temperature: 0
- 추론을 사용해서는 안 됨

다음 프롬프트 템플릿을 사용합니다.

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

예시:

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

코드 및 문제 해결

이 장에서는 Amazon Nova 모델을 효과적으로 사용하는 데 도움이 되는 코드 예제와 문제 해결 지침을 제공합니다.

코드 라이브러리

이 섹션에서는 Converse API 또는 InvokeModel API를 사용하는 일반적인 Amazon Nova 작업에 대한 코드 예제를 제공합니다.

Converse API 예제

기본 요청

Converse API를 사용하여 Amazon Nova 모델에 기본 텍스트 요청을 전송합니다.

Non-streaming

```
import boto3
from botocore.config import Config

# Create the Bedrock Runtime client, using an extended timeout configuration
# to support long-running requests.
bedrock = boto3.client(
    "bedrock-runtime",
    region_name="us-east-1",
    config=Config(read_timeout=3600),
)

# Invoke the model
response = bedrock.converse(
    modelId="us.amazon.nova-2-lite-v1:0",
    messages=[
        {
            "role": "user",
            "content": [{"text": "Write a short story. End the story with 'THE\nEND'.",}],
        }
    ],
    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)

```

임베디드 자산을 사용하는 멀티모달 입력

요청에 문서, 이미지, 비디오 또는 오디오 데이터를 직접 포함하여 멀티모달 콘텐츠를 처리합니다. 이 예제에서는 이미지 데이터를 사용합니다. 다른 양식의 콘텐츠 구조에 대한 자세한 내용은 [Amazon Bedrock API 설명서의 ContentBlock 세부 정보](#)를 참조하세요.

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)

```

S3 URI를 사용하는 멀티모달 입력

S3에 저장된 문서, 이미지, 비디오 또는 오디오 파일을 참조하여 멀티모달 콘텐츠를 처리합니다. 이 예제에서는 이미지 참조를 사용합니다. 다른 양식의 콘텐츠 구조에 대한 자세한 내용은 [Amazon Bedrock API 설명서의 ContentBlock 세부 정보](#)를 참조하세요.

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)
```

확장된 사고 사용(추론)

복잡한 문제 해결 태스크에 대해 확장된 사고를 활성화합니다.

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

```

기본 제공 도구: 인용을 사용하는 Nova 그라운드링

Nova 그라운드링을 사용하여 인용을 통해 웹에서 실시간 정보를 검색합니다.

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)
```

기본 제공 도구: 코드 인터프리터

코드 인터프리터 도구를 사용하여 계산 및 데이터 분석을 위해 Python 코드를 실행합니다.

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)

```

도구 사용

모델이 대화 중에 사용할 사용자 지정 도구를 정의합니다.

Non-streaming

```

import boto3
from botocore.config import Config

def get_weather(city):
    # Mock function to simulate weather API
    return {"temperatureF": 48, "conditions": "light rain"}

```

```
# Define the toolSpec for the weather tool
weather_tool = {
    "toolSpec": {
        "name": "get_weather",
        "description": "Get the current weather conditions in a given location",
        "inputSchema": {
            "json": {
                "type": "object",
                "properties": {
                    "city": {
                        "type": "string",
                        "description": "The city and state, e.g. San Francisco, CA",
                    }
                },
                "required": ["city"],
            }
        },
    }
}

# Define the list of tools the model may use
tool_config = {"tools": [weather_tool]}

# Create the Bedrock Runtime client, using an extended timeout configuration
# to support long-running requests.
bedrock = boto3.client(
    "bedrock-runtime",
    region_name="us-east-1",
    config=Config(read_timeout=3600),
)

# Start tracking message history
messages = []

messages.append(
    {
        "role": "user",
        "content": [
            {
                "text": "Suggest some activities to do in Seattle based on the
current weather."
            }
        ],
    }
)
```

```
)

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

assistant_message = response["output"]["message"]

# Add the assistant response to the message history
messages.append(assistant_message)

content_list = assistant_message["content"]
stop_reason = response["stopReason"]

if stop_reason == "tool_use":
    # Extract the toolUse details
    tool_use = next(
        content["toolUse"] for content in content_list if "toolUse" in content
    )
    tool_name = tool_use["name"]
    tool_use_id = tool_use["toolUseId"]

    if tool_name == "get_weather":
        # Call the tool
        weather = get_weather(tool_use["input"]["city"])

        # Send the result back to the model
        messages.append(
            {
                "role": "user",
                "content": [
                    {
                        "toolResult": {
                            "toolUseId": tool_use_id,
                            "content": [{"json": weather}],
                        }
                    }
                ],
            }
        )

    # Submit the tool result back to the model
    response = bedrock.converse(
```

```

        modelId="us.amazon.nova-2-lite-v1:0",
        messages=messages,
        toolConfig=tool_config,
    )

    content_list = response["output"]["message"]["content"]
    for content in content_list:
        # Extract the text response
        if "text" in content:
            print("\n== Text ==")
            print(content["text"])
    else:
        # A tool call was not needed
        for content in content_list:
            # Extract the text response
            if "text" in content:
                print("\n== Text ==")
                print(content["text"])

```

Streaming

```

import boto3
from botocore.config import Config
import json

def get_weather(city):
    # Mock function to simulate weather API
    return {"temperatureF": 48, "conditions": "light rain"}

# Define the toolSpec for the weather tool
weather_tool = {
    "toolSpec": {
        "name": "get_weather",
        "description": "Get the current weather conditions in a given location",
        "inputSchema": {
            "json": {
                "type": "object",
                "properties": {
                    "city": {
                        "type": "string",
                        "description": "The city and state, e.g. San Francisco, CA",

```



```

        }
    },
    "required": ["city"],
}
},
}
}

# Define the list of tools the model may use
tool_config = {"tools": [weather_tool]}

# Create the Bedrock Runtime client, using an extended timeout configuration
# to support long-running requests.
bedrock = boto3.client(
    "bedrock-runtime",
    region_name="us-east-1",
    config=Config(read_timeout=3600),
)

# Start tracking message history
messages = []

messages.append(
    {
        "role": "user",
        "content": [
            {
                "text": "Suggest some activities to do in Seattle based on the
current weather."
            }
        ],
    }
)

# Invoke the model with streaming
response = bedrock.converse_stream(
    modelId="us.amazon.nova-2-lite-v1:0", messages=messages, toolConfig=tool_config
)

# Process the streaming response
assistant_message = {"role": "assistant", "content": []}
current_tool_use = None
stop_reason = None

```

```
for event in response["stream"]:
    if "contentBlockStart" in event:
        start = event["contentBlockStart"]["start"]
        if "toolUse" in start:
            current_tool_use = start["toolUse"]
            current_tool_use["input"] = ""

    elif "contentBlockDelta" in event:
        delta = event["contentBlockDelta"]["delta"]
        if "toolUse" in delta:
            current_tool_use["input"] += delta["toolUse"]["input"]
        elif "text" in delta:
            print(delta["text"], end="", flush=True)

    elif "contentBlockStop" in event:
        if current_tool_use:
            # Parse the accumulated tool input
            current_tool_use["input"] = json.loads(current_tool_use["input"])
            assistant_message["content"].append({"toolUse": current_tool_use})
            current_tool_use = None

    elif "messageStop" in event:
        stop_reason = event["messageStop"]["stopReason"]
        if stop_reason == "end_turn":
            exit

# Add the assistant response to the message history
messages.append(assistant_message)

if stop_reason == "tool_use":
    # Extract the toolUse details
    tool_use = next(
        content["toolUse"]
        for content in assistant_message["content"]
        if "toolUse" in content
    )
    tool_name = tool_use["name"]
    tool_use_id = tool_use["toolUseId"]

    if tool_name == "get_weather":
        # Call the tool
        weather = get_weather(tool_use["input"]["city"])

        # Send the result back to the model
```

```

messages.append(
    {
        "role": "user",
        "content": [
            {
                "toolResult": {
                    "toolUseId": tool_use_id,
                    "content": [{"json": weather}],
                }
            }
        ],
    }
)

# Submit the tool result back to the model with streaming
response = bedrock.converse_stream(
    modelId="us.amazon.nova-2-lite-v1:0",
    messages=messages,
    toolConfig=tool_config,
)

# Handle the final streaming response
print("\n== Text ==")
for event in response["stream"]:
    if "contentBlockDelta" in event:
        delta = event["contentBlockDelta"]["delta"]
        if "text" in delta:
            print(delta["text"], end="", flush=True)

```

InvokeModel API 예제

아래 예제에서는 Invoke API의 요청 및 응답 구조가 Converse API의 요청 및 응답 구조와 조금 다른 몇 가지 주요 영역에 초점을 맞춥니다. 대부분의 다른 방법에서는 두 API가 호환되므로, InvokeModel API와 함께 작동하도록 위의 Converse API 예제를 쉽게 조정할 수 있습니다.

기본 요청

InvokeModel API를 사용하여 Amazon Nova 2 모델에 기본 텍스트 요청을 전송합니다.

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)
```

추론을 사용하는 InvokeModel API

복잡한 문제 해결을 위한 추론이 활성화된 상태로 InvokeModel API를 사용합니다.

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)

```

문제 해결

이 섹션에서는 Amazon Nova 모델 작업 시 발생하는 일반적인 문제에 대한 해결 방법을 제공합니다.

인증 및 설정

권한 누락

증상: Nova 모델이나 기능에 액세스할 수 없음

해결 방법:

- IAM 역할에 AmazonBedrockFullAccess 또는 적절한 권한이 있는지 확인
- Amazon Bedrock 콘솔을 통해 특정 모델 액세스 요청

- 모델 액세스 및 도구 사용에 대한 권한 확인

모델 액세스 거부됨

증상: 모델 액세스 요청 실패

해결 방법:

- Amazon Bedrock 콘솔을 통해 특정 모델 액세스 요청
- 요청된 모델에 대한 액세스 권한이 계정에 부여되었는지 확인
- 모델의 리전별 가용성 확인

리전별 가용성 문제

증상: 선택한 리전에서 기능을 사용할 수 없음

해결 방법:

- 웹 그라운드링은 미국 리전, 미국 CRIS 프로파일에서만 사용할 수 있음
- 선택한 리전에서 모델 및 기능을 사용할 수 있는지 확인
- 필요한 경우 지원되는 리전으로 전환

제한 시간 구성

증상: 완료 전 요청 제한 시간 초과

원인: 복잡한 작업에 대해 기본 제한 시간이 너무 짧음

해결 방법: 확장된 제한 시간 설정 구성

```
from botocore.config import Config

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

 Note

Amazon Nova 추론 요청은 복잡한 작업에서 최대 60분이 걸릴 수 있습니다.

API 응답 문제

중지 이유 이해:

`end_turn`

정상 완료. 별도의 조치가 필요하지 않습니다.

`max_tokens`

토큰 제한에 도달했습니다.

해결 방법: `inferenceConfig`에서 `maxTokens` 파라미터를 늘립니다.

`content_filtered`

콘텐츠가 AWS의 책임 있는 AI 정책을 위반했습니다.

해결 방법: 콘텐츠 정책을 준수하도록 입력을 검토하고 수정합니다.

`malformed_model_output`

유효하지 않은 출력 형식입니다.

해결 방법: 출력 스키마 및 제약 조건을 확인하고 JSON 스키마의 형식이 올바른지 확인합니다.

`malformed_tool_use`

유효하지 않은 도구 직접 호출 형식입니다.

해결 방법: 도구 정의가 예상 스키마와 일치하는지 확인하고 도구 입력 파라미터의 형식이 올바른지 확인합니다.

`service_unavailable`

기본 제공 도구 서비스를 사용할 수 없습니다.

해결 방법: 짧은 지연 후 요청을 재시도하고 AWS 서비스 상태 대시보드를 확인합니다.

invalid_query

기본 제공 도구에 대한 유효하지 않은 쿼리입니다.

해결 방법: 쿼리 형식 및 파라미터를 검토하고 쿼리가 도구 요구 사항을 충족하는지 확인합니다.

max_tool_invocations

도구 재시도 횟수가 소진되었습니다.

해결 방법: 태스크를 단순화하거나 더 작은 단계로 나누고 도구 오류 메시지에서 특정 문제를 검토합니다.

추론 모드 오류

추론 노력이 많이 드는 잘린 응답

해결 방법: 추론 노력이 많이 드는 경우 temperature, topP, maxToken과 같은 파라미터를 설정 해제합니다. 그러면 모델은 복잡한 추론 태스크에 대한 최적의 설정을 사용할 수 있습니다.

추론을 위한 토큰 부족

오류: 'maxTokens is insufficient'

해결 방법: 제한을 늘려 자동으로 재시도

```
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

```

도구 사용 문제

스키마 검증 실패

도구 스키마 검증 오류

해결 방법:

- 최상의 성능을 위해 JSON 스키마를 중첩 계층 2개로 제한
- 모든 필수 필드가 올바르게 정의되었는지 확인
- JSON 스키마 사양을 기반으로 스키마 검증

모델이 도구를 올바르게 사용하지 않음

해결 방법:

- 도구 이름에서 목적을 명확하게 설명하는지 확인
- 도구 기능에 대한 자세한 설명 제공
- 명확한 파라미터 설명을 통해 명시적으로 입력 스키마 정의
- 도움이 되는 경우 설명에 예제 포함

일관되지 않은 도구 직접 호출 동작

해결 방법: 도구 직접 호출 시 온도를 0으로 설정합니다.

```

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

```

그러면 보다 신뢰할 수 있는 도구 사용을 위한 복잡한 디코딩이 가능합니다.

도구 선택 충돌

문제: 웹 검색 또는 코드 인터프리터와 함께 사용자 지정 도구를 사용할 때 오류 발생

해결 방법: 이름이 nova_grounding인 사용자 지정 toolSpec을 포함하지 마세요. 이는 시스템 도구와 충돌합니다. 대신 시스템 도구 구성을 사용합니다.

```
# 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", ...}
#     }]
# }
```

웹 그라운드링 문제

액세스 제어 문제

문제: 웹 그라운드링 및 코드 인터프리터가 작동하지 않음

해결 방법: IAM 정책에 다음이 포함되었는지 확인합니다.

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

서비스 제어 정책 문제

문제: SCP에 의해 웹 그라운드링이 차단됨

해결 방법: aws:requestedRegion 조건을 포함하는 서비스 제어 정책이 있는 경우 웹 그라운드링 기능에 대해 'unspecified' 리전을 허용하도록 업데이트합니다.

미디어 처리 제한 사항

이미지/비디오에서 다국어 콘텐츠에 대한 이해 부족

제한 사항: Nova 모델은 시각적 미디어에서 다국어 콘텐츠에 대한 이해가 제한적임

해결 방법:

- 이미지와 함께 텍스트 번역 제공
- 가능한 경우 다국어 콘텐츠에 대해 텍스트 기반 입력 사용

사람 식별

문제: 모델이 이미지에서 사람 식별을 거부함

예상 동작: 모델은 개인 정보 보호 및 안전상의 이유로 이미지, 문서 또는 비디오에서 개인을 식별하거나 이름을 지정하는 작업을 거부함

해결 방법: 특정 자격 증명 대신 일반적인 특성이나 컨텍스트에 대해 질문

공간 추론 제한 사항

문제: 부정확한 현지화 또는 레이아웃 분석

제한 사항: 정확한 공간 추론의 제한된 기능

해결 방법:

- 객체 현지화에 대해 경계 상자 탐지 사용
- 프롬프트에서 명확한 참조 지점 제공
- 복잡한 공간 쿼리를 더 단순한 구성 요소로 구분

이미지/비디오의 작은 텍스트

문제: 미디어에서 작은 텍스트를 읽을 수 없음

해결 방법:

- 관련 텍스트 섹션에 초점을 맞추도록 이미지 자르기
- 소스 미디어 해상도 증가
- 사용 가능한 경우 별도로 텍스트 제공

문서 및 파일 처리

지원되지 않는 콘텐츠

문제: PDF 처리 실패

원인:

- CMYK 색상 프로필을 포함하는 PDF
- SVG 이미지를 포함하는 PDF

해결 방법:

- PDF를 RGB 색상 프로필로 변환
- PDF에 포함하기 전에 SVG 이미지 래스터화

토큰 추정

문제: PDF에서 예기치 않은 토큰 사용

지침: 표준 8.5×11" PDF 페이지당 약 2,560개의 토큰 추정

해결 방법: 문서 길이에 따라 적절히 maxTokens 조정

API 및 SDK 참조

이 섹션에서는 Amazon Nova API 및 SDK에 대한 전체 기술 참조 설명서를 제공합니다.

주제

- [요청 및 응답 스키마](#)
- [SDK 참조](#)

요청 및 응답 스키마

요청 스키마는 Invoke API(스트리밍 및 비스트리밍)와 Converse API 사이에서 거의 동일합니다. 주요 차이는 바이너리 데이터(이미지, 비디오, 오디오)가 인코딩되는 방식입니다. Converse API는 바이너리 배열을 사용하지만, Invoke API는 Base64 인코딩 문자열을 사용합니다.

전체 요청 구조

다음에서는 Amazon Nova 모델의 전체 요청 구조를 보여줍니다. 필수로 표시되지 않는 한 모든 필드는 선택 사항입니다.

```
{
  "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"
    }
  }
}

```

주요 요청 파라미터:

- **system**: 컨텍스트 및 지침을 제공하는 시스템 프롬프트
- **messages**: 역할(사용자 또는 어시스턴트) 및 콘텐츠를 포함하는 대화 턴 배열
- **inferenceConfig**: 모델 출력 동작(온도, 토큰 등) 제어

- toolConfig: 함수 직접 호출을 위한 도구 사양

Note

Converse API를 사용하는 경우 inferenceConfig 대신 additionalModelRequestFields에서 topK 및 reasoningConfig 파라미터를 배치해야 합니다.

다음 섹션에서는 각 요청 파라미터에 대한 자세한 설명을 제공합니다.

시스템

system - (선택 사항) 요청에 대한 시스템 프롬프트입니다. 시스템 프롬프트에서는 특정 목표 또는 역할 지정과 같은 컨텍스트와 지침을 Amazon Nova에 제공합니다.

messages

messages - (필수) 대화 턴을 포함하는 입력 메시지 배열입니다.

- role - (필수) 대화 턴의 역할입니다. 유효 값은 user 및 assistant입니다. 첫 번째 메시지는 항상 user 역할을 사용해야 합니다.
- content - (필수) 콘텐츠 블록의 배열입니다. 각 블록은 콘텐츠 유형(text, image, video 또는 audio)을 지정합니다.
 - text - 대화 턴의 텍스트 콘텐츠입니다. 이미지 또는 비디오와 결합된 경우 함께 제공되는 텍스트로 해석됩니다.
 - image - (Nova 2 Lite에서 지원되지 않음) 다음을 포함하는 이미지 콘텐츠:
 - format - (필수) 이미지 형식: jpeg, png, webp 또는 gif
 - source.bytes - (필수) 바이너리 배열(Converse API) 또는 Base64 문자열(Invoke API)의 이미지 데이터
 - video - (Nova 2 Lite에서 지원되지 않음) 다음을 포함하는 비디오 콘텐츠:
 - format - (필수) 비디오 형식: mkv, mov, mp4, webm, three_gp, flv, mpeg, mpg 또는 wmv
 - source - (필수) S3 URI(s3Location.uri 및 선택적 bucketOwner) 또는 파일 바이트(bytes)를 통한 비디오 소스
 - audio - (Amazon Nova Sonic만 해당) 다음을 포함하는 오디오 콘텐츠:
 - format - (필수) 오디오 형식: mp3, opus, wav, aac, flac, mp4, ogg 또는 mkv

- `source` – (필수) S3 URI 또는 파일 바이트를 통한 오디오 소스

inferenceConfig

`inferenceConfig` – (선택 사항) 모델 출력 생성을 제어하는 구성 파라미터입니다.

- `maxTokens` – (선택 사항) 중지하기 전에 생성할 최대 토큰 수입니다. Amazon Nova 모델은 이 제한에 도달하기 전에 중지될 수 있습니다. 최대값은 5,000입니다. 지정하지 않으면 요청 컨텍스트를 기반으로 동적 기본값을 사용합니다.
- `temperature` – (선택 사항) 응답의 무작위성입니다. 유효한 범위: 0.00001~1(기본값: 0.7). 값이 낮을수록 더 결정적인 출력이 생성됩니다.
- `topP` – (선택 사항) Nucleus 샘플링 임계치입니다. 누적 확률이 `topP`에 도달하는 토큰에서 Amazon Nova 샘플입니다. 유효한 범위: 0~1(기본값: 0.9). 둘 다 아닌 `temperature` 또는 `topP` 중 하나를 조정합니다.
- `topK` – (선택 사항) 최상위 K개의 토큰에서만 샘플을 구합니다. 확률이 낮은 응답을 제거합니다. 유효한 범위: 0~128(기본값: 사용되지 않음).

Note

Converse API의 경우 `additionalModelRequestFields`에서 `topK`를 전달합니다.

- `stopSequences` – (선택 사항) 발생 시 생성을 중지하는 문자열 배열입니다.
- `reasoningConfig` – (Amazon Nova Sonic만 해당) 추론 구성:
 - `type` – (선택 사항) `enabled` 또는 `disabled`(기본값: `disabled`)
 - `maxReasoningEffort` - 컴퓨팅 작업: `low`, `medium` 또는 `high`. `low` 및 `medium`을 사용하면 추론 스트림이 증분식으로 스트리밍되고 `high`는 최종 청크에서 추론을 출력합니다.

Note

Converse API의 경우 `additionalModelRequestFields`에서 `reasoningConfig`를 전달합니다.

toolConfig

`toolConfig` – (선택 사항) [ToolConfiguration 스키마](#)에 따른 도구 구성입니다.

- tools - name, description 및 inputSchema를 사용하는 도구 사양 배열
- toolChoice - (선택 사항) 다음과 같이 도구 선택을 제어합니다.
 - auto - 모델이 사용할 도구와 도구의 사용 여부를 결정함
 - any - 모델이 하나 이상의 도구를 사용해야 함
 - tool - 모델이 이름을 기준으로 지정된 도구를 사용해야 함

전체 응답 구조

다음에서는 Amazon Nova 모델의 전체 응답 구조를 보여줍니다.

```
{
  "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
}
}

```

중지 이유:

- `end_turn`: 자연스러운 응답 종료
- `max_tokens`: `maxTokens` 제한에 도달함
- `content_filtered`: 콘텐츠 정책을 위반함
- `malformed_model_output`: 유효하지 않은 모델 출력
- `malformed_tool_use`: 유효하지 않은 도구 사용 출력
- `service_unavailable`: 기본 제공 도구 서비스에 연결할 수 없음
- `invalid_query`: 기본 제공 도구에 대한 유효하지 않은 쿼리
- `max_tool_invocations`: 도구 재시도 횟수가 소진됨

다음 섹션에서는 각 응답 필드에 대한 자세한 설명을 제공합니다.

output

output – (필수) 모델의 응답 메시지를 포함합니다.

- message – (필수) 역할 및 콘텐츠 배열을 포함하는 어시스턴트의 응답 메시지입니다.
- content – (필수) 다음을 포함할 수 있는 콘텐츠 블록 배열입니다.
 - reasoningContent – (선택 사항) 추론이 활성화된 경우 반환됩니다. 항상 응답에서 [REDACTED]인 추론 텍스트를 포함합니다.
 - toolUse – (선택 사항) 도구가 호출된 경우 반환됩니다. 도구 사용 ID, 이름 및 입력 인수를 포함합니다.
 - text – (선택 사항) 모델이 텍스트 콘텐츠로 응답한 경우 반환됩니다.
 - image – (선택 사항, 전용) 모델이 이미지를 생성한 경우 반환됩니다. 항상 PNG 형식입니다.

stopReason

stopReason – (필수) 모델이 출력 생성을 중지한 이유를 나타냅니다.

- end_turn - 자연스러운 응답 종료에 도달함
- max_tokens - maxTokens 제한 또는 모델의 최대 출력 제한에 도달함
- content_filtered - 출력이 AWS의 책임 있는 AI 정책을 위반함
- malformed_model_output - 모델이 유효하지 않은 출력을 생성함
- malformed_tool_use - 모델이 유효하지 않은 도구 사용 출력을 생성함
- service_unavailable - 기본 제공 도구 서비스에 연결할 수 없음
- invalid_query - 기본 제공 도구에 대한 쿼리가 유효하지 않음
- max_tool_invocations - 기본 제공 도구가 재시도 후 유효한 결과를 생성하지 않음

사용

usage – (필수) 토큰 사용량 정보:

- inputTokens - 모델에서 수집한 총 토큰
- outputTokens - 생성된 토큰 수
- totalTokens - 입력 및 출력 토큰의 합계

지표

metrics – (필수) 성능 지표:

- latencyMs - 총 추론 완료 시간(밀리초)

SDK 참조

다양한 프로그래밍 언어에 대해 AWS 소프트웨어 개발 키트(SDK)를 사용할 수 있습니다. 각 SDK는 개발자가 선호하는 언어로 애플리케이션을 쉽게 구축할 수 있도록 하는 API, 코드 예제 및 설명서를 제공합니다.

SDK 설명서	코드 예제
AWS SDK for C++	AWS SDK for C++ 코드 예제
AWS CLI	AWS CLI 코드 예제
Go용 AWS SDK	AWS SDK for Go 코드 예제
Java용 AWS SDK	AWS SDK for Java 코드 예제
AWS SDK for JavaScript	AWS SDK for JavaScript 코드 예제
AWS SDK for Kotlin	AWS SDK for Kotlin 코드 예제
.NET용 AWS SDK	AWS SDK for .NET 코드 예제
AWS SDK for PHP	AWS SDK for PHP 코드 예제
AWSTools for PowerShell	AWS Tools for PowerShell 코드 예제
Python용 AWS SDK(Boto3)	AWS SDK for Python(Boto3) 코드 예제
Ruby용 AWS SDK	AWS SDK for Ruby 코드 예제
AWS SDK for Rust	AWS SDK for Rust 코드 예제
AWS SDK for SAP ABAP	AWS SDK for SAP ABAP 코드 예제
AWS SDK for Swift	AWS SDK for Swift 코드 예제

SageMaker AI에서 Amazon Nova 모델 사용자 지정

[레시피](#)를 사용하여 향상된 Amazon Nova 2.0 모델을 포함한 Amazon Nova 모델을 사용자 지정하고 SageMaker에서 훈련할 수 있습니다. 이러한 레시피는 지도 미세 조정(SFT) 및 강화 미세 조정(RFT)과 같은 기법을 지원하며, 이와 함께 전체 순위 및 저순위 적응(LoRA) 옵션을 모두 포함합니다.

엔드 투 엔드 사용자 지정 워크플로에는 추론을 위한 모델 훈련, 모델 평가 및 배포와 같은 단계가 포함됩니다. SageMaker에서 이 모델 사용자 지정 접근 방식은 지원되는 Amazon Nova 모델을 미세 조정하고, 하이퍼파라미터를 정밀하게 최적화하며, LoRA 파라미터 효율 미세 조정(PEFT), 전체 순위 SFT, RFT, 지속적인 사전 훈련(CPT)과 같은 기술을 구현할 수 있는 높은 유연성과 제어를 제공합니다.

사용자 지정 접근 방식

SageMaker는 Amazon Nova 모델을 사용자 지정하기 위한 두 가지 접근 방식을 제공합니다.

UI 기반 경험 - 단순한 안내 인터페이스를 통해 Amazon Nova 모델을 사용자 지정하는 데 사용합니다. 이 접근 방식은 코드를 작성하지 않고도 훈련, 평가 및 배포를 포함한 포괄적인 워크플로를 제공합니다. UI 기반 경험은 빠른 실험, 개념 증명 개발 및 시각적 워크플로를 선호하는 사용자에게 적합합니다.

코드 기반 경험 - SageMaker Python SDK, Nova SDK 및 훈련 레시피를 사용하여 프로그래밍 방식으로 모델을 사용자 지정합니다. 이 접근 방식은 유연성을 높여 고급 하이퍼파라미터를 구성하고, CI/CD 파이프라인과 통합하며, 훈련 워크플로를 자동화할 수 있습니다. 코드 기반 경험은 프로덕션 워크로드, 복잡한 사용자 지정 요구 사항 및 MLOps 관행이 확립된 팀에 권장됩니다.

접근 방식	최적의 용도	주요 이점
UI 기반	실험, 프로토타입 제작, 빠른 반복	단순한 설정, 안내 워크플로, 코딩 필요 없음
코드 기반	프로덕션, 자동화, 고급 구성	완전한 유연성, 파이프라인 통합, 버전 제어

사용자 지정 플랫폼

AWS에서는 Amazon Nova 모델을 사용자 지정하기 위한 세 가지 플랫폼을 제공하며, 각 플랫폼은 여러 사용 사례 및 요구 사항에 맞게 설계되었습니다.

Amazon Bedrock - 최소한의 설정으로 모델 사용자 지정을 위한 가장 쉽고 빠른 경로를 제공합니다. Bedrock은 모든 인프라 관리를 자동으로 처리하므로 사용자가 데이터와 사용 사례에 집중할 수 있습니다. 이 플랫폼은 가장 빠른 가치 창출을 필요로 하고 완전관리형 환경을 선호하는 경우에 적합합니다.

SageMaker 훈련 작업 - 클러스터를 생성하거나 유지 관리할 필요가 없는 Amazon Nova 모델을 사용자 지정하기 위한 완전관리형 환경을 제공합니다. 서비스가 모든 인프라 프로비저닝, 확장 및 리소스 관리를 자동으로 처리하므로 사용자는 훈련 파라미터를 구성하고 작업을 제출하는 데 집중할 수 있습니다. 이 플랫폼은 사용 편의성과 유연성 간의 균형을 제공하며, 파라미터 효율 미세 조정(PEFT), 전체 순위 미세 조정 및 강화 미세 조정(RFT)과 같은 기술을 지원합니다.

SageMaker HyperPod - 제한된 인스턴스 그룹(RIG)으로 EKS 클러스터를 생성 및 관리해야 하므로 대규모 분산 훈련을 위한 특수한 환경을 제공합니다. 이 플랫폼을 사용하면 특수 GPU 인스턴스와 통합 Amazon FSx for Lustre 스토리지로 훈련 환경을 최대한 유연하게 구성할 수 있으므로 고급 분산 훈련 시나리오와 지속적인 모델 개발, 엔터프라이즈급 사용자 지정 워크로드에 특히 적합합니다.

플랫폼	복잡성	유연성	최적의 용도
Amazon Bedrock	가장 낮음	표준	가장 빠른 사용자 지정, 최소한의 설정
SageMaker 훈련 작업	중간	높음	균형 잡힌 유연성과 사용 편의성
SageMaker HyperPod	가장 높음	최대	대규모 분산 훈련, 엔터프라이즈 워크로드

Note

Amazon 소유 출력 S3 버킷에서 암호화를 위해 Amazon Nova 모델 사용자 지정 훈련 작업에 KMS 키를 제공하는 경우:

- 후속 반복 훈련 작업을 직접 호출하거나 암호화된 모델을 활용하여 Amazon Bedrock CreateCustomModel API를 직접 호출할 때 동일한 KMS 키를 제공해야 합니다.
- CreateTrainingJob API를 직접 호출하는 ID(실행 역할이 아님)에는 KMS 키 정책에 정의된 대로 CreateGrant, RetireGrant, Encrypt, GenerateDataKey에 대한 권한이 있어야 합니다.

일반적인 사전 요구 사항

사용자 지정 프로세스에는 각각 특정 리소스와 구성이 필요한, 추론을 위한 모델 훈련, 평가 및 배포를 비롯한 여러 주요 단계가 포함됩니다. SageMaker에서 Amazon Nova 모델 사용자 지정을 시작하기 전에 다음과 같은 일반 사전 조건이 있는지 확인하세요.

- AWS 계정. AWS 계정이 없는 경우 [다음 지침](#)에 따라 가입합니다.
- [AWS CLI](#) 설치 및 [구성 설정](#).
- [기본 Amazon Nova 모델 사용자 지정 레시피](#)에 대한 액세스.
- [YAML](#) 구성 파일에 대한 지식.
- 환경에서 노트북을 실행하는 방법에 대한 익숙한 경험.
- [Amazon S3 버킷](#) 및 [적절한 권한이 있는 IAM 역할](#)과 같은 AWS 리소스를 생성하는 방법에 대한 지식.
- [SageMaker로 모델을 훈련](#)하는 방법에 대한 익숙한 경험.
- [SageMaker HyperPod와 EKS 오케스트레이션](#)에 대한 익숙한 경험.
- [SageMaker HyperPod CLI](#)에 대한 익숙한 경험.
- [Amazon Nova 파운데이션 모델](#)에 대한 지식.
- [사용자 지정에 사용할 수 있는 Amazon Nova 모델 및 알고리즘](#)에 대한 지식.
- [Amazon Bedrock 추론](#)에 대한 지식.

Amazon Nova 레시피

[SageMaker HyperPod 레시피](#) 리포지토리에서 Amazon Nova 레시피를 가져올 수 있습니다. Amazon Nova 레시피는 SageMaker가 모델 사용자 지정 작업을 수행하는 방법에 대한 세부 정보를 제공하는 [YAML](#) 구성 파일입니다. 이 레시피는 기본 모델 이름을 제공하고, 훈련 하이퍼파라미터를 설정하고, 최적화 설정을 정의하고, 모델을 성공적으로 미세 조정하거나 훈련하는 데 필요한 추가 옵션을 포함합니다.

또한 SageMaker AI Monarch를 통해서도 Nova 레시피에 액세스할 수 있습니다. 모델 허브로 이동하여 AWS를 선택하고 Amazon Nova 모델을 검색해 관련 레시피를 찾으시면 됩니다. SageMaker AI Monarch는 각 레시피에 대한 샘플 노트북을 제공합니다. 이 노트북에는 레시피를 수정하고 SageMaker AI 훈련 작업 또는 Amazon SageMaker HyperPod 환경을 사용하여 사용자 지정 작업을 실행하는 데 필요한 모든 단계가 포함되어 있습니다.

Amazon SageMaker Studio의 레시피 페이지에 액세스하려면 실행 역할에 다음 권한이 있어야 합니다.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "s3:GetObject"
      ],
      "Resource": [
        "arn:aws:s3:::*model-customization-recipes*"
      ]
    }
  ]
}
```

SageMaker 훈련 작업 및 SageMaker HyperPod에서 샘플 노트북을 실행하려면 SageMaker 배포 이 미지 버전 2.7.1+, 2.8.0+, 3.2.1+, 3.3.0+ 중 하나를 사용하세요. 이는 SageMaker AI Monarch에 적용됩니다.

주제

- [Amazon Nova 레시피 가져오기](#)
- [Amazon Nova Forge 레시피 가져오기](#)
- [사용 가능한 모델 및 알고리즘](#)
- [Amazon Nova 2.0 Lite](#)

Amazon Nova 레시피 가져오기

기본 Amazon Nova 레시피를 가져오려면 다음 명령을 실행하여 [SageMaker HyperPod 레시피](#) 리포지 토리를 복제합니다.

```
git clone https://github.com/aws/sagemaker-hyperpod-recipes.git
```

기본 레시피는 [recipes_collection/recipes/](#)에서 사용할 수 있습니다.

```
cd recipes_collection/recipes/
```

Amazon Nova 사용자 지정 레시피는 다음 폴더에 있습니다.

레시피 유형	폴더
SFT(전체 순위 및 PEFT)	fine-tuning/nova
평가	evaluation/nova
CPT	training/nova

Amazon Nova Forge 레시피 가져오기

작업을 위한 특수 Amazon Nova Forge 레시피에 액세스하려면 [Amazon Nova Forge에 대한 액세스를 설정](#)한 다음, [이 워크숍](#)에 따라 CLI의 Forge 버전을 설정합니다. SageMaker 훈련 작업의 경우 AWS 콘솔 및 Nova Forge SDK는 Forge 레시피에 자동으로 액세스합니다.

사용 가능한 모델 및 알고리즘

다음 표에는 SageMaker를 사용한 Amazon Nova 모델 및 지원되는 알고리즘에 대한 사용자 지정 가용성이 요약되어 있습니다.

모델 이름	모델 ID	미세 조정	참고
Amazon Nova Lite 2.0	amazon.nova-2-lite-v1:0:256k	예	- SFT - 텍스트 및/또는 이미지, 또는 텍스트 및/또는 비디오를 입력으로 받아 텍스트를 출력합니다. 단일 작업의 동일한 실행에서 텍스트, 이미지 및 비디오를 결합할 수 없습니다. - RFT - 텍스트와 이미지를 싱글턴 대화의 입력으로 수락하고 출력으로 텍스트

모델 이름	모델 ID	미세 조정	참고
			를 생성합니다. 보상 최적화 기능을 개선했습니다.
			CPT

Amazon Nova 2.0 Lite

아래 표에는 Amazon Nova 2.0 Lite 레시피 참조에 대한 자세한 정보가 나와 있습니다.

모델	범주/하위 범주	기술	레시피 이름	이미지 URI(훈련 작업)	이미지 URI(SageMaker HyperPod)	컴퓨팅 인스턴스
Nova 2.0 Lite	학습	지속적인 사전 훈련	nova_lite_2_0_p5x8_gpu_pretrain.yaml	해당 사항 없음	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-CPT-V2-latest	m1.p5.48xlarge, m1.p5en.48xlarge
Nova 2.0 Lite	파라미터 효율적 미세 조정	미세 조정	nova_lite_2_0_p5_gpu_lora_sft.yaml	708977205387.dkr.ecr.us-east-1.amazo	708977205387.dkr.ecr.us-east-1.amazo	m1.p5.48xlarge, m1.p5en.48xlarge

모델	범주/하위 범주	기술	레시피 이름	이미지 URI(훈련 작업)	이미지 URI(SageMaker HyperPod)	컴퓨팅 인스턴스
				naws.com/nova-fine-tune-repo:SM-TJ-SFT-V2-latest	naws.com/nova-fine-tune-repo:SM-HP-SFT-V2-latest	
Nova 2.0 Lite	전체 순위 미세 조정	미세 조정	nova_lite_2_0_p5_gpu_sft.yaml	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-TJ-SFT-V2-latest	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-SFT-V2-latest	m1.p5.48xlarge, m1.p5en.48xlarge

모델	범주/하위 범주	기술	레시피 이름	이미지 URI(훈련 작업)	이미지 URI(SageMaker HyperPod)	컴퓨팅 인스턴스
Nova 2.0 Lite	파라미터 효율적 RFT	미세 조정	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

모델	범주/하위 범주	기술	레시피 이름	이미지 URI(훈련 작업)	이미지 URI(SageMaker HyperPod)	컴퓨팅 인스턴스
Nova 2.0 Lite	전체 순위 RFT	미세 조정	nova_lite_v2_smtj_p5en_gpu_rft.yaml	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-TJ-RFT-V2-latest	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-RFT-TRAIN-V2-latest	m1.p5.48xlarge, m1.p5en.48xlarge

모델	범주/하위 범주	기술	레시피 이름	이미지 URI(훈련 작업)	이미지 URI(SageMaker HyperPod)	컴퓨팅 인스턴스
Nova 2.0 Lite	자체 데이터 사용	평가	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	m1.p5.48xlarge, m1.p5en.48xlarge
Nova 2.0 Lite	일반 텍스트 벤치마크	평가	nova_lite_2_0_p5_48x1_gpu_general_text_benchmark_eval.yaml	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-TJ-Eval-V2-1-atest	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-HP-Eval-V2-1-atest	m1.p5.48xlarge, m1.p5en.48xlarge

모델	범주/하위 범주	기술	레시피 이름	이미지 URI(훈련 작업)	이미지 URI(SageMaker HyperPod)	컴퓨팅 인스턴스
Nova 2.0 Lite	RFT 평가	평가	nova_lite_2_0_p5_48x1_gpu_rft_eval.yaml	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-TJ-Eval-V2-1atest	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-HP-Eval-V2-1atest	ml.p5.48xlarge , ml.p5en.48xlarge
Nova 2.0 Lite	LLM Rubric 기반 평가	평가	nova_lite_2_0_p5_48x1_gpu_rubric_llm_judge_eval.yaml	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-TJ-Eval-V2-1atest	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-HP-Eval-V2-1atest	ml.p5.48xlarge , ml.p5en.48xlarge

SageMaker 훈련 작업에서 Amazon Nova 사용자 지정

SageMaker 훈련 작업은 기계 학습 모델을 대규모로 훈련할 수 있는 환경입니다. 컴퓨팅 리소스를 자동으로 프로비저닝 및 확장하고, Amazon S3와 같은 소스에서 훈련 데이터를 로드하고, 훈련 코드를 실행하고, 결과 모델 아티팩트를 저장합니다.

훈련의 목적은 독점 데이터를 사용하여 기본 Amazon Nova 모델을 사용자 지정하는 것입니다. 훈련 프로세스에는 일반적으로 데이터를 준비하고, [레시피](#)를 선택하며, YAML 파일에서 구성 파라미터를 수정하고, 훈련 작업을 제출하는 단계가 포함됩니다. 훈련 프로세스는 훈련된 모델 체크포인트를 서비스 관리형 Amazon S3 버킷에 출력합니다. 이 체크포인트 위치를 평가 작업에 사용할 수 있습니다. SageMaker AI 훈련 작업에서 Nova 사용자 지정을 수행하면, 모델 아티팩트가 서비스 관리형 Amazon S3 버킷에 저장됩니다. 서비스 관리형 버킷의 아티팩트는 SageMaker AI 관리형 KMS 키로 암호화됩니다. 현재 서비스 관리형 Amazon S3 버킷은 고객 관리형 KMS 키를 사용한 데이터 암호화를 지원하지 않습니다.

Amazon Nova 사용자 지정 모범 사례

개요

이 섹션에서는 사용자 지정 기법에 대한 개요를 제공하고, 요구 사항과 사용 가능한 데이터에 가장 적합한 접근 방식을 선택하는 데 도움을 줍니다.

LLM 훈련의 두 가지 단계

대규모 언어 모델 훈련은 두 가지 주요 단계(사전 훈련 및 사후 훈련)로 구성됩니다. 사전 훈련 단계에서 모델은 원시 텍스트의 토큰을 처리하고 다음 토큰 예측을 위해 최적화됩니다. 이 프로세스에서는 웹 및 업로드된 텍스트에서 구문, 시맨틱, 사실 및 추론 패턴을 흡수하는 패턴 완성기를 생성합니다. 그러나 사전 훈련된 모델은 지침, 사용자 목표 또는 컨텍스트별 동작을 이해하지 못합니다. 훈련 배포에 맞는 스타일로 텍스트를 계속 처리합니다. 사전 훈련된 모델은 지침을 따르는 대신 자동 완성을 수행하고, 일치하지 않는 형식을 생성하며, 훈련 데이터에서 원치 않는 편향이나 안전하지 않은 콘텐츠를 미러링할 수 있습니다. 사전 훈련에서는 태스크 유용성이 아닌 일반적인 기능을 구축합니다.

사후 훈련에서는 패턴 완성기를 유용한 어시스턴트로 변환합니다. 여러 차례의 감독 미세 조정(SFT)을 실행하여 모델이 지침을 따르고, 스키마 및 정책을 준수하며, 도구를 직접 호출하고, 고품질 데모를 모방하여 신뢰할 수 있는 출력을 생성하도록 가르칩니다. 이 조정을 통해 계속 진행하려면 텍스트가 아닌 태스크로 프롬프트에 응답하도록 모델을 가르칩니다. 그런 다음 강화 미세 조정(RFT)을 적용하여 측정 가능한 피드백(예: 확인자 또는 평가형 LLM), 정확도와 간결성, 안전과 적용 범위 또는 제약 조건 아래에서 여러 단계의 추론과 같은 장단점의 균형을 맞춰 동작을 최적화합니다. 실제로 SFT와 RFT를 주기

적으로 교체하여 사전 훈련된 모델을 복잡한 태스크를 일관되게 수행하는 신뢰할 수 있는 정책 조정 시스템으로 구축합니다.

올바른 사용자 지정 접근 방식 선택

이 섹션에서는 사후 훈련 사용자 지정 전략(RFT 및 SFT)을 다룹니다.

강화 미세 조정(RFT)

강화 미세 조정은 정확히 올바른 답변으로 직접 감독하는 대신 응답 품질을 나타내는 피드백 신호(측정 가능한 점수 또는 보상)를 통해 모델 성능을 개선합니다. 입력과 출력 페어로부터 학습하는 기존의 지도 미세 조정과 달리, RFT는 보상 함수를 사용하여 모델 응답을 평가하고 반복적으로 모델을 최적화하여 이러한 보상을 극대화합니다. 이 접근 방식은 정확히 올바른 출력을 정의하기 어려운 태스크에 효과적이지만 신뢰할 수 있는 방식으로 응답 품질을 측정할 수 있습니다. RFT를 사용하면 모델이 시험과 피드백을 통해 복잡한 행동과 선호도를 학습할 수 있으므로, 세심한 의사 결정, 창의적인 문제 해결 또는 프로그래밍 방식으로 평가할 수 있는 특정 품질 기준 준수가 필요한 애플리케이션에 적합합니다. 예를 들어 복잡한 법적 질문에 대한 답변은 RFT의 이상적인 사용 사례입니다. 질문에 더 정확하게 답변하는 방법을 모델에 가르치고 싶기 때문입니다.

작동 방식

강화 미세 조정에서는 지침 조정 기준에서 시작하여 각 프롬프트를 작은 토너먼트와 같이 처리합니다. 주어진 입력에 대해 모델의 몇 가지 후보 답변을 샘플링하고 보상 함수로 각각의 점수를 매긴 후 해당 그룹 내에서 순위를 정합니다. 업데이트 단계에서는 다음에 점수가 내려가지 않고 점수가 더 높아질 수 있도록 모델을 유도하면서, 기존 유지 제약 조건을 통해 동작이 드리프팅되거나 장황해지거나 악용되는 것을 방지합니다. 많은 프롬프트에서 이 루프를 반복하여 하드 케이스를 새로 고치고, 악용이 발견되면 확인자 또는 평가 루브릭을 강화하며, 태스크 지표를 지속적으로 추적합니다.

RFT는 사용하는 경우

RFT를 가장 많이 활용하는 태스크는 몇 가지 특성을 공유합니다. 하나의 올바른 출력을 지정하기 어려운 경우에도 측정 가능한 성공 신호를 제공합니다. 부분 크레딧 또는 등급이 지정된 품질을 인정하므로 프롬프트 내에서 또는 보상 함수를 사용하여 더 좋거나 나쁜 응답의 순위를 정할 수 있습니다. 여기에는 균형을 맞춰야 하는 여러 목표(예: 간결함, 명확함, 안전 또는 비용을 고려한 정확성)가 포함됩니다. 프로그래밍 방식으로 확인할 수 있는 명시적 제약 조건을 준수해야 합니다. 결과를 관찰할 수 있는 도구로 조정되는 설정 또는 환경 기반 설정(성공 또는 실패, 지연 시간, 리소스 사용)에서 작동합니다. 이는 골드 타겟을 수집하는 데 비용이 많이 들지만 자동 피드백이나 루브릭 기반 피드백이 많은 낮은 수준의 레이블 영역에서 나타납니다. RFT는 품질을 신뢰할 수 있는 스칼라 또는 순위로 전환하고 레이블이 지정된 전수 대상 없이도 모델이 더 높은 점수의 동작을 우선적으로 증폭하도록 하는 경우에 가장 효과적입니다.

다음과 같은 경우 다른 방법을 고려합니다.

- 신뢰할 수 있는 많은 레이블이 지정된 입력과 출력 페어가 있는 경우 - SFT 사용
- 기본 격차가 지식 또는 전문 용어에서 발생하는 경우 - 검색 증강 생성(RAG) 사용
- 보상 신호에 노이즈가 있거나 이를 신뢰할 수 없으며 더 나은 루브릭이나 검사기로 수정할 수 없는 경우 - RFT 이전에 먼저 안정화

RFT를 사용하지 말아야 하는 경우

다음과 같은 상황에서는 RFT를 사용하지 않습니다.

- 신뢰할 수 있는 레이블이 지정된 입력과 출력 페어를 저렴하게 생성할 수 있는 경우(SFT가 더 단순하고 저렴하며 안정적임)
- 격차는 동작이 아닌 지식 또는 전문 용어에서 발생하는 경우(RAG 사용)
- 보상 신호에 노이즈가 있거나 희소하거나 쉽게 훈련이 가능하거나 비용이 많이 들거나 컴퓨팅 속도가 느린 경우(먼저 평가자 수정)
- 기존 성능이 0에 가까운 경우(선호도를 최적화하기 전에 SFT로 부트스트랩)
- 태스크에 결정적 스키마, 엄격한 형식 또는 단일 정답이 포함된 경우(SFT 또는 규칙 기반 검증이 더 효과적임)
- 긴 지연 시간 또는 비용 예산인 RFT에 필요한 추가 샘플링 또는 탐색을 수용할 수 없는 경우
- 안전 또는 정책 제약 조건이 명확하게 지정되지 않고 보상에서 적용 가능하지 않은 경우

'정답'을 가리킬 수 있는 경우 SFT를 사용합니다. 새로운 지식이 필요한 경우 RAG를 사용합니다. 견고한 기준과 강력하고 빠르며 악용하기 어려운 보상 함수가 있는 경우에만 RFT를 사용합니다.

지도 미세 조정(SFT)

감독 미세 조정은 태스크에 대해 사람이 레이블을 지정하는 입력과 출력 페어의 데이터셋을 기반으로 LLM을 훈련합니다. 올바른 응답이나 원하는 응답과 함께 프롬프트의 예제(질문, 지침 등)를 제공하고 이를 기반으로 모델을 계속 훈련합니다. 모델은 지도 손실(일반적으로 예측과 대상 출력 토큰 사이의 교차 엔트로피)를 최소화하도록 해당 가중치를 조정합니다. 이는 대부분의 지도 기계 학습 태스크에 사용되는 것과 동일한 훈련으로, LLM을 전문화하는 데 적용됩니다.

SFT는 지식이 아닌 동작을 변경합니다. 사전 훈련에서 나타나지 않았던 새로운 사실이나 전문 용어를 모델에 가르치지 않습니다. 모델에 알아야 할 내용이 아닌 어떻게 답변하는지를 가르칩니다. 새로운 도메인 지식(예: 내부 용어)이 필요한 경우 검색 증강 생성(RAG)을 사용하여 추론 시 해당 컨텍스트를 제공합니다. 그런 다음 SFT는 원하는 지침 준수 동작을 맨 위에 추가합니다.

작동 방식

SFT는 응답 토큰의 평균 교차 엔트로피 손실을 최소화하고 프롬프트 토큰을 컨텍스트로 처리하며 손실로부터 해당 정보를 마스킹하여 LLM을 최적화합니다. 모델은 대상 스타일, 구조 및 의사 결정 규칙을 내재화하여 각 프롬프트에 대해 올바른 완성 항목을 생성하는 방법을 학습합니다. 예를 들어 문서를 사용자 지정 카테고리로 분류하려면 프롬프트(문서 텍스트)와 레이블이 지정된 완성 항목(카테고리 레이블)으로 모델을 미세 조정합니다. 모델이 높은 확률로 각 프롬프트에 올바른 레이블을 출력할 때까지 해당 페어에서 훈련합니다.

몇백 개의 소수 예제만으로 SFT를 수행하다가 수십만 개로 스케일 업할 수 있습니다. SFT 샘플은 고품질이어야 하며 원하는 모델 동작에 맞게 직접 조정되어야 합니다.

SFT는 사용하는 경우

원하는 출력이 명확한 잘 정의된 태스크가 있는 경우 SFT를 사용합니다. 'X' 입력 제공, 올바른 출력은 'Y'라고 명시적으로 말할 수 있고 이러한 매핑의 예제를 수집할 수 있는 경우 지도 미세 조정이 적합합니다. SFT는 다음 시나리오에서 뛰어납니다.

- 구조화되거나 복잡한 분류 태스크 - 내부 문서 또는 계약을 여러 사용자 지정 카테고리로 분류합니다. SFT를 사용하면 모델은 프롬프트만 사용할 때보다 이러한 특정 카테고리를 훨씬 더 잘 학습할 수 있습니다.
- 알려진 답변이 있는 질문 답변 또는 변환 태스크 - 회사의 지식 베이스를 통해 질문에 답변하거나 각 입력에 올바른 응답이 있는 경우 여러 형식 사이에서 데이터를 변환하도록 모델을 미세 조정합니다.
- 형식 지정 및 스타일 일관성 - 올바른 형식이나 어조의 예제를 미세 조정하여 모델이 항상 특정 형식 또는 어조로 응답하도록 훈련합니다. 예를 들어 특정 브랜드 음성을 보여주는 프롬프트와 응답 페어에서 훈련하는 경우 해당 스타일로 출력을 생성하도록 모델을 가르칩니다. 지침 준수 동작은 종종 처음에 SFT를 통해 선별된 올바른 어시스턴트 동작 예제를 사용하여 학습됩니다.

SFT는 올바른 동작을 지정할 수 있는 경우 LLM에 새로운 기술이나 동작을 가르치는 가장 직접적인 방법입니다. 그리고 모델의 기존 언어 이해를 사용하고 태스크에 집중합니다. 모델이 특정 작업을 수행하도록 하고 예제 데이터셋을 생성하거나 생성할 수 있는 경우 SFT를 사용합니다.

원하는 동작을 밀접하게 미러링하는 고품질 프롬프트 및 응답 페어를 조합할 수 있는 경우 SFT를 사용합니다. 스키마, 함수 또는 도구 직접 호출, 모방이 적절한 훈련 신호인 구조화된 답변과 같은 명확한 대상이나 결정적 형식이 있는 태스크에 적합합니다. 목표는 동작을 구성하는 것입니다. 즉, 프롬프트를 태스크로 처리하고, 지침을 따르며, 어조 및 거부 정책을 채택하고, 일관된 형식을 생성하도록 모델을 가르칩니다. 원시 볼륨보다 데이터 품질, 일관성 및 중복 제거가 더 중요한 수백 개 이상의 데모를 계획

합니다. 직관적이고 비용 효율적인 업데이트를 위해 저순위 적응과 같은 파라미터 효율적 메서드를 사용하여 대부분의 백본을 그대로 유지하면서 소형 어댑터를 훈련합니다.

SFT를 사용하지 말아야 하는 경우

격차가 동작이 아닌 지식인 경우 SFT를 사용하지 마세요. 모델에 새로운 사실, 전문 용어 또는 최근 이벤트를 가르치지 않습니다. 이러한 경우 검색 증강 생성을 사용하여 추론 시 외부 지식을 가져옵니다. 품질을 측정할 수 있지만 하나의 올바른 답변에 레이블을 지정할 수 없는 경우 SFT를 사용하지 마세요. 확인 가능한 보상 또는 평가형 LLM로 강화 미세 조정을 사용하여 이러한 보상을 직접 최적화합니다. 요구 사항이나 콘텐츠가 자주 변경되는 경우 모델을 재훈련하는 대신 검색 및 도구 사용에 의존하세요.

주제

- [Nova Forge SDK](#)
- [Amazon Nova 모델에 대한 훈련](#)
- [여러 반복에서 진행 상황 모니터링](#)
- [SageMaker AI로 훈련된 모델 평가](#)
- [반복 학습](#)

Nova Forge SDK

Nova Forge SDK는 Amazon Nova 모델을 사용자 지정하기 위한 포괄적인 Python SDK입니다. 이 SDK에서는 SageMaker AI 및 Amazon Bedrock을 비롯한 다양한 플랫폼에서 Amazon Nova 모델의 훈련, 평가, 모니터링, 배포 및 추론을 위한 통합 인터페이스를 제공합니다. 모델을 도메인별 태스크에 맞게 적응하든 사용 사례에 맞게 성능을 최적화하든 관계없이 이 SDK는 하나의 통합 인터페이스에서 필요한 모든 기능을 제공합니다.

이점

- 데이터 준비부터 배포 및 모니터링에 이르기까지 전체 모델 사용자 지정 수명 주기를 위한 단일 SDK.
- 지속적인 사전 훈련(CPT), 지도 미세 조정(SFT), 직접 선호 최적화(DPO), 강화 미세 조정(RFT), 싱글턴 및 멀티턴 모두를 포함하여 LoRA 및 전체 순위 접근 방식을 함께 여러 훈련 방법에 대한 지원.
- 자동 리소스 관리를 통해 SageMaker 훈련 작업 및 SageMaker HyperPod, Amazon Bedrock에 대한 기본 제공 지원.
- 훈련 기법에 적합한 레시피 또는 컨테이너 URI를 더 이상 찾을 필요 없음.

- 자체 훈련 레시피를 가져오거나 파라미터 재정의와 함께 SDK의 지능형 기본값을 사용합니다.
- 이 SDK는 지원되는 모델 및 인스턴스 조합에 대해 구성을 검증하고 검증 지원을 제공하여 훈련이 시작되기 전에 오류를 방지합니다.
- 통합 Amazon CloudWatch 모니터링을 사용하면 훈련 진행 상황을 실시간으로 추적할 수 있습니다.
- MLFlow를 통합하여 SageMaker AI MLFlow 추적 서버로 훈련 실험을 추적합니다.

요구 사항

SDK에는 Python 3.12 이상이 필요합니다.

설치

이 SDK를 설치하려면 아래 명령을 따르세요.

```
pip install amzn-nova-forge
```

지원되는 모델 및 기법

이 SDK는 Amazon Nova 패밀리 내에서 다음과 같은 모델과 기법을 지원합니다.

방법	지원되는 모델
지속적인 사전 훈련	모든 Nova 모델 (SMHP만 해당)
지도 미세 조정 LoRA	모든 Nova 모델
지도 미세 조정 전체 순위	모든 Nova 모델 (SMHP 및 SMTJ만 해당)
직접 선호 최적화 LoRA	Nova 1.0 모델(SMHP 및 SMTJ만 해당)
직접 선호 최적화 전체 순위	Nova 1.0 모델(SMHP 및 SMTJ만 해당)
강화 미세 조정 LoRA	Nova Lite 2.0
강화 미세 조정 전체 순위	Nova Lite 2.0(SMHP 및 SMTJ만 해당)
멀티턴 강화 미세 조정 LoRA	Nova Lite 2.0(SMHP만 해당)
멀티턴 강화 미세 조정 전체 순위	Nova Lite 2.0(SMHP만 해당)

시작하기

주제

- [1. 데이터 준비](#)
- [2. 인프라 구성](#)
- [3. 훈련](#)
- [4. 모니터링](#)
- [5. 평가](#)
- [6. 배포](#)

1. 데이터 준비

로컬 파일 또는 S3에서 데이터셋을 로드하고 SDK가 선택한 훈련 방법에 맞는 올바른 형식으로 변환을 처리하게 합니다. 또는 형식이 지정된 데이터를 제공하고 즉시 시작합니다.

```
from amzn_nova_forge.dataset.dataset_loader import JSONLDatasetLoader
from amzn_nova_forge.model.model_enums import Model, TrainingMethod

loader = JSONLDatasetLoader(question="input", answer="output")
loader.load("s3://your-bucket/training-data.jsonl")
loader.transform(method=TrainingMethod.SFT_LORA, model=Model.NOVA_LITE)
```

2. 인프라 구성

컴퓨팅 리소스를 선택합니다. SDK에서 구성을 검증하고 최적의 설정을 보장합니다.

```
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. 훈련

몇 줄의 코드만으로 훈련을 시작합니다.

```
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. 모니터링

SDK에서 훈련 진행 상황을 직접 추적합니다.

```
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. 평가

다양한 [기본 제공 벤치마크](#)를 사용하여 모델 성능을 평가하거나 자체 평가를 설계합니다.

```
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. 배포

Amazon Bedrock 또는 SageMaker에 대한 기본 지원을 통해 사용자 지정 모델을 프로덕션에 배포합니다.

```
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",
    }
)
```

주요 기능

즉시 레시피 생성

이 SDK를 사용하면 특정 기법에 적절한 레시피 또는 컨테이너 URI를 검색할 필요가 없습니다.

지능형 데이터 처리

SDK에서 훈련을 위한 올바른 형식으로 데이터를 자동 변환합니다. JSON, JSONL 또는 CSV 파일로 작업하는 경우 데이터 로더에서 변환을 원활하게 처리합니다. 데이터 로더는 텍스트와 멀티모달 데이터(이미지 및 비디오)를 지원합니다.

엔터프라이즈 인프라 지원

이 SDK는 SageMaker 훈련 작업과 SageMaker HyperPod 모두에서 작동하며 다음을 자동으로 관리합니다.

- 인스턴스 유형 검증
- 레시피 검증
- 데이터세트 검증
- 작업 오케스트레이션 및 모니터링

SDK는 SageMaker 훈련 작업 서버리스 및 Bedrock 사용자 지정도 지원합니다.

포괄적인 평가

다음에 포함된 [표준 벤치마크](#)를 기준으로 사용자 지정된 모델을 평가합니다.

- Massive Multitask Language Understanding(MMLU)
- 고급 추론 작업(BBH)
- Graduate-Level Google-Proof Q&A(GPQA)

벤치마크 기본값을 사용하거나 필요에 맞게 수정합니다.

- 자체 지표 가져오기(BYOM)
- 자체 데이터세트 가져오기(BYOD)

프로덕션 배포

다음에 대한 옵션을 사용하여 Amazon Bedrock 또는 SageMaker AI에 모델을 배포합니다.

- Bedrock 프로비저닝된 처리량 - 일관된 성능을 위한 전용 용량
- Bedrock 온디맨드(LoRA 기반 사용자 지정에만 해당) - 종량제 요금
- Sagemaker AI 실시간 추론 - 일관된 성능을 위한 전용 용량

배치 추론

대규모 추론 작업을 효율적으로 실행합니다.

- 수천 개의 요청을 병렬로 처리
- 자동 결과 집계
- 비용 효율적인 배치 처리

Nova Forge

Nova Forge 구독자의 경우 SDK는 데이터 혼합 레시피를 지원합니다.

자세히 알아보기

Nova Forge SDK를 사용하여 Nova 모델 사용자 지정을 시작할 준비가 되셨나요? 자세한 가이드, API 참조 및 추가 예제는 GitHub 리포지토리(<https://github.com/aws/nova-forge-sdk>)를 참조하세요.

Amazon Nova 모델에 대한 훈련

SageMaker 훈련 작업에서 Amazon Nova 모델을 훈련하는 경우 지시 미세 조정(SFT) 및 강화 미세 조정(RFT)을 지원합니다. 각 기법은 다양한 사용자 지정 요구 사항을 충족하며 여러 Amazon Nova 모델 버전에 적용할 수 있습니다.

주제

- [Nova 2.0 미세 조정](#)
- [Amazon Nova 모델을 사용한 강화 미세 조정\(RFT\)](#)

Nova 2.0 미세 조정

사전 조건

훈련 작업을 시작하기 전에 다음을 확인하세요.

- 입력 데이터와 훈련 작업 출력을 저장하는 Amazon S3 버킷. 두 가지 데이터를 하나의 버킷에 함께 저장하거나, 각 데이터 유형을 별도의 버킷에 저장할 수 있습니다. 버킷이 모든 훈련 관련 리소스를 생성하는 AWS 리전과 동일한 리전에 있는지 확인합니다. 자세한 내용은 [범용 버킷 생성](#)을 참조하세요.
- 훈련 작업 실행 권한이 있는 IAM 역할. IAM 정책을 AmazonSageMakerFullAccess에 연결해야 합니다. 자세한 내용은 [How to use SageMaker AI execution roles](#)를 참조하세요.
- 기본 Amazon Nova 레시피, [???](#) 참조.

SFT란 무엇인가요?

지도 미세 조정(SFT)은 레이블이 지정된 입력 및 출력 페어를 사용하여 언어 모델을 훈련합니다. 모델은 프롬프트와 응답으로 구성된 데모 예제로부터 학습하여 특정 태스크, 지침 또는 원하는 동작에 맞게 해당 기능을 개선합니다.

데이터 준비

개요

Nova 2.0 SFT 데이터는 선택적 추론 콘텐츠 필드를 추가하여 Nova 1.0과 동일한 Converse API 형식을 사용합니다. 전체 형식 사양은 다음을 참조하세요.

- 추론 콘텐츠: [ReasoningContentBlock](#)
- Converse API 스키마: [Converse API](#)
- 데이터세트 제약 조건: [데이터세트 제약 조건](#)

지원되는 기능

- 입력 유형 - 사용자 콘텐츠 블록의 텍스트, 이미지 또는 비디오
- 어시스턴트 콘텐츠 - 텍스트 전용 응답 및 추론 콘텐츠
- 데이터세트 구성 - 동종이어야 합니다. 다음 중 하나를 선택합니다.
 - 텍스트 전용 톰

- 텍스트 + 이미지 턴
- 텍스트 + 비디오 턴(문서 이해 지원)

Important

동일한 데이터세트 내에서 또는 다른 턴에 이미지와 비디오를 혼합할 수 없습니다.

현재 제한 사항

- 멀티모달 추론 콘텐츠 - Converse 형식은 이미지 기반 추론 콘텐츠를 지원하지만 Nova 2.0 SFT는 reasoningText 필드에서 텍스트 기반 추론 콘텐츠만 지원합니다.
- 검증 세트 - Nova 2.0을 사용하는 SFT에 대한 검증 데이터세트를 제공할 수 없습니다. 검증 데이터 세트를 제공하면 훈련 중에 무시됩니다. 이 제한 사항은 UI 기반 및 프로그래밍 방식 작업 제출 모두에 적용됩니다.

지원되는 미디어 형식

- 이미지 - PNG, JPEG, GIF
- 비디오 - MOV, MKV, MP4

데이터 형식 예제

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"
    }
  ]
}
```

도구 직접 호출

Nova 2.0 SFT는 도구 직접 호출 패턴에서 모델 훈련을 지원하므로 모델은 외부 도구 또는 함수를 간접 호출하는 시점과 방법을 배울 수 있습니다.

도구 직접 호출을 위한 데이터 형식

훈련 데이터를 직접 호출하는 도구에는 도구 사용 패턴을 보여주는 대화 턴과 함께 사용 가능한 도구를 정의하는 toolConfig 섹션이 포함되어 있습니다.

샘플 입력

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

```

도구 직접 호출 요구 사항

훈련 데이터를 직접 호출하는 도구를 생성할 때 다음 요구 사항을 따릅니다.

요구 사항	설명
ToolUse 배치	ToolUse는 어시스턴트 턴에만 표시되어야 함
ToolResult 배치	ToolResult는 사용자 턴에만 표시되어야 함
ToolResult 형식	ToolResult는 텍스트 또는 JSON 전용이어야 합니다. Nova 모델에서는 다른 양식이 지원되지 않음
inputSchema 형식	toolSpec 내 inputSchema는 유효한 JSON 스키마 객체여야 함
toolUseId 일치	각 ToolResult는 이전 어시스턴트 ToolUse에서 유효한 toolUseId를 참조해야 하며, 이때 각 toolUseId는 대화당 정확히 한 번만 사용됨

중요 정보

- 모든 훈련 샘플에서 도구 정의가 일관된지 확인
- 모델은 사용자가 제공하는 데모에서 도구 간접 호출 패턴을 학습함
- 각 도구를 사용해야 하는 경우와 도구를 사용하지 않아야 하는 경우에 관한 다양한 예제를 포함함

문서 이해

Nova 2.0 SFT는 문서 기반 태스크에 대한 훈련을 지원하므로 모델이 PDF 문서에 대한 질문을 분석하고 이에 응답하는 방법을 배울 수 있습니다.

문서 이해를 위한 데이터 형식

문서 이해 훈련 데이터에는 문서 콘텐츠에서 추출하고 추론하는 모델 학습과 함께 사용자 콘텐츠 블록의 문서 참조가 포함됩니다.

샘플 입력

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

```

문서 이해 제한 사항

제한 사항	세부 정보
지원되는 형식	PDF 파일만
최대 문서 크기	10MB
양식 혼합	샘플에는 문서와 텍스트가 있을 수 있지만, 문서를 다른 양식(이미지, 비디오)과 혼합할 수는 없음

문서 이해 모범 사례

- 문서의 형식이 명확하게 지정되고 텍스트를 추출할 수 있는지 확인
- 여러 문서 유형 및 질문 형식을 포괄하는 다양한 예제 제공
- 모델이 문서 분석 패턴을 학습하는 데 도움이 되는 추론 콘텐츠 포함

비디오 이해

Nova 2.0 SFT는 비디오 기반 태스크에 대한 훈련을 지원하므로 모델이 비디오 콘텐츠에 대한 질문을 분석하고 이에 응답하는 방법을 배울 수 있습니다.

비디오 이해를 위한 데이터 형식

비디오 이해 훈련 데이터에는 정보를 추출하고 비디오 콘텐츠에서 추론하는 모델 학습과 함께 사용자 콘텐츠 블록의 비디오 참조가 포함됩니다.

샘플 입력

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

```

비디오 이해 제한 사항

제한 사항	세부 정보
최대 비디오 크기	50MB
최대 비디오 지속 시간	15분
샘플당 비디오 수	샘플당 하나의 비디오만 허용됩니다. 동일한 샘플에서 여러 개의 비디오는 지원되지 않음
양식 혼합	샘플에는 비디오와 텍스트가 있을 수 있지만, 비디오를 다른 양식(이미지, 문서)과 결합할 수는 없음

지원되는 비디오 형식

- MOV
- MKV
- MP4

비디오 이해 모범 사례

- 비디오를 간결하게 유지하고 태스크와 관련된 콘텐츠에 집중함
- 모델이 의미 있는 정보를 추출하기에 비디오 품질이 충분한지 확인

- 비디오 콘텐츠의 특정 측면을 참조하는 명확한 질문 제공
- 여러 비디오 유형 및 질문 형식을 포괄하는 다양한 예제 포함

추론 모드 및 비추론 모드 비교

추론 콘텐츠 이해

추론 콘텐츠(연쇄적 사고라고도 함)는 최종 답변을 생성하기 전에 모델의 중간 사고 단계를 캡처합니다. assistant 턴에서 reasoningContent 필드를 사용하여 이러한 추론 트레이스를 포함합니다.

손실 계산 방법

- 추론 콘텐츠 포함 - 훈련 손실에 추론 토큰과 최종 출력 토큰이 모두 포함됨
- 추론 콘텐츠 제외 - 훈련 손실은 최종 출력 토큰에서만 계산됨

멀티턴 대화의 여러 어시스턴트 턴에서 reasoningContent를 포함할 수 있습니다.

형식 지침

- 추론 콘텐츠에 대해 일반 텍스트 사용
- 태스크에 특별히 필요하지 않은 한 <thinking> 및 </thinking>과 같은 마크업 태그 방지
- 추론 콘텐츠가 명확하고 문제 해결 프로세스와 관련이 있는지 확인

추론 모드를 활성화하는 경우

다음과 같은 경우 훈련 구성에서 reasoning_enabled: true를 설정합니다.

- 훈련 데이터에 추론 토큰이 있는 경우
- 최종 출력을 생성하기 전에 모델에서 사고 토큰을 생성하려는 경우
- 복잡한 추론 태스크에서 성능 개선이 필요한 경우

reasoning_enabled = true를 사용하여 비추론 데이터세트에서 Nova 훈련이 허용됩니다. 그러나 Nova는 주로 추론을 적용하지 않고 데이터에 표시된 응답을 생성하는 방법을 배우기 때문에 이 경우 모델이 추론 기능을 상실할 수 있습니다. 비추론 데이터세트에서 Nova를 훈련하고 싶지만 유추 중에도 추론을 기대하는 경우 훈련 중에 추론을 비활성화하되(reasoning_enabled = false) 유추를 위해 추론을 활성화할 수 있습니다. 이 접근 방식을 사용하면 유추 시 추론을 사용할 수 있지만 추론이 없는 유추와 비교했을 때 성능 개선을 보장하지 않습니다. 일반적으로 추론 데이터세트를 사용할 때는 훈련

및 유추 모두에 대한 추론을 활성화하고, 비추론 데이터세트를 사용할 때는 둘 다에 대해 추론을 비활성화합니다.

다음과 같은 경우에 `reasoning_enabled: false`를 설정합니다.

- 훈련 데이터에 추론 토큰이 없는 경우
- 명시적 추론 단계의 이점을 얻지 못하는 간단한 태스크에서 훈련하는 경우
- 속도를 최적화하고 토큰 사용량을 줄이려는 경우

추론 데이터 생성

데이터세트에 추론 트레이스가 없는 경우 Nova Premier와 같은 추론 지원 모델을 사용하여 생성할 수 있습니다. 모델에 입력 및 출력 페어를 제공하고 해당 추론 프로세스를 캡처하여 추론 증강 데이터세트를 구축합니다.

훈련에 대해 추론 토큰 사용

추론 모드가 활성화된 상태에서 훈련하면 모델은 내부 추론을 최종 답변과 분리하는 방법을 학습합니다. 훈련 프로세스:

- 입력, 추론 및 답변과 같은 트리플로 데이터를 구성함
- 추론 토큰과 답변 토큰 모두에서 표준 다음 토큰 예측 손실을 사용하여 최적화함
- 응답을 생성하기 전에 모델의 내부 추론을 장려함

효과적인 추론 콘텐츠

고품질 추론 콘텐츠에는 다음이 포함되어야 합니다.

- 중간 사고 및 분석
- 논리적 연역 및 추론 단계
- 단계별 문제 해결 접근 방식
- 단계와 결론 사이에서 명시적 연결

그러면 모델이 '답변하기 전에 사고'하는 기능을 개발하는 데 도움이 됩니다.

데이터세트 준비 지침

크기 및 품질

- 권장 크기 - 2,000~10,000개의 샘플
- 최소 샘플 수 - 200
- 우선순위 - 수량보다 품질을 우선합니다. 예제가 정확하고 주석이 잘 달렸는지 확인합니다.
- 애플리케이션 정렬 - 데이터세트는 프로덕션 사용 사례를 긴밀하게 반영해야 함

다양성

다음과 같은 다양한 예제를 포함합니다.

- 예상 입력의 전체 범위 포괄
- 여러 난이도 표시
- 엡지 케이스 및 변형 포함
- 패턴 범위를 좁히기 위해 과적합 방지

출력 형식

어시스턴트 응답에서 원하는 출력 형식을 명확하게 지정합니다.

- JSON 구조
- 테이블
- CSV 형식
- 애플리케이션별 사용자 지정 형식

멀티턴 대화

멀티턴 데이터세트의 경우 다음 사항에 유의하세요.

- 손실은 사용자 턴이 아닌 어시스턴트 턴에서만 계산됨
- 각 어시스턴트 응답의 형식이 올바르게 지정되어야 함
- 여러 대화 턴에서 일관성 유지 관리

품질 체크리스트

- 충분한 데이터세트 크기(2K~10K 샘플)
- 모든 사용 사례를 포괄하는 다양한 예제
- 명확하고 일관된 출력 형식 지정
- 정확한 레이블 및 주석
- 프로덕션 시나리오 대변
- 모순이나 모호성이 없음

데이터 업로드

데이터세트는 SageMaker 훈련 작업에서 액세스할 수 있는 버킷에 업로드해야 합니다. 올바른 권한 설정에 대한 자세한 내용은 [사전 조건](#)을 참조하세요.

훈련 작업 시작

하이퍼파라미터 선택 및 레시피 업데이트

Nova 2.0의 설정은 Nova 1.0의 설정과 거의 동일합니다. 입력 데이터가 S3에 업로드되면 미세 조정 폴더에서 [SageMaker HyperPod 레시피](#)의 레시피를 사용합니다. Nova 2.0의 경우 다음은 사용 사례에 따라 업데이트할 수 있는 몇 가지 주요 하이퍼파라미터입니다. 다음은 Nova 2.0 SFT PEFT 레시피에 대한 예제입니다. 컨테이너 이미지 URI의 경우 `708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-TJ-SFT-V2-latest`를 사용하여 SFT 미세 조정 작업을 실행합니다.

Nova 훈련과의 엄격한 호환성을 위해 SageMaker AI PySDK의 v2.254.1을 사용하세요. SDK를 v3.0 버전으로 업그레이드하면 호환되지 않는 변경 내용이 발생합니다. SageMaker AI PySDK v3에 대한 지원은 곧 제공될 예정입니다.

샘플 입력

```
!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

```


이 레시피에는 Nova 1.0과 거의 동일한 하이퍼파라미터도 포함되어 있습니다. 주목할 만한 하이퍼파라미터는 다음과 같습니다.

- `max_steps` - 작업을 실행하려는 단계 수입니다. 일반적으로 하나의 에포크(전체 데이터세트를 통해 하나가 실행됨)의 경우 단계 수 = 데이터 샘플 수/글로벌 배치 크기입니다. 단계 수가 많고 글로벌 배치 크기가 작을수록 작업 실행 시간이 길어집니다.
- `reasoning_enabled` - 데이터세트의 추론 모드를 제어합니다. 옵션:
 - `true`: 추론 모드 활성화(높은 노력의 추론과 동일)
 - `false`: 추론 모드 비활성화

참고: SFT의 경우 추론 노력 수준을 세밀하게 제어하지 않습니다. `reasoning_enabled: true`를 설정하면 전체 추론 기능이 활성화됩니다.

- `peft.peft_scheme` - 이를 'lora'로 설정하면 PEFT 기반 미세 조정이 활성화됩니다. null(따옴표 없음)로 설정하면 전체 순위 미세 조정이 활성화됩니다.

훈련 작업 시작

```
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

Nova 2.0의 지도 미세 조정에는 검증 데이터세트 전달이 지원되지 않습니다.

작업을 시작하는 방법:

- 데이터세트 경로 및 하이퍼파라미터로 레시피 업데이트
- 노트북에서 지정된 셀을 실행하여 훈련 작업 제출

노트북은 작업 제출을 처리하고 상태 추적을 제공합니다.

Amazon Nova 모델을 사용한 강화 미세 조정(RFT)

개요

RCF란 무엇인가요?

강화 미세 조정(RFT)은 올바른 정답이 아닌 측정 가능한 점수나 모델의 성과를 나타내는 보상인 피드백 신호에서 훈련하여 모델 성능을 개선합니다. 입력과 출력 페어로부터 학습하는 지도 미세 조정과 달리, RFT는 보상 함수를 사용하여 모델 응답을 평가하고 반복적으로 모델을 최적화하여 이러한 보상을 극대화합니다. 이 접근 방식은 정확히 올바른 출력을 정의하기 어려운 태스크에 효과적이지만 신뢰할 수 있는 방식으로 응답 품질을 측정할 수 있습니다.

RFT는 사용하는 경우

명확하고 측정 가능한 성공 기준을 정의할 수 있지만 훈련에 정확히 올바른 출력을 제공하는 데 어려움을 겪는 경우 RFT를 사용합니다. 다음과 같은 경우에 적합합니다.

- 품질이 주관적이거나 다면적인 태스크(창의적 글쓰기, 코드 최적화, 복잡한 추론)
- 일부 솔루션이 다른 솔루션보다 명확하게 더 나은 여러 개의 유효한 솔루션이 있는 시나리오
- 반복된 개선, 개인화 또는 복잡한 비즈니스 규칙 준수가 필요한 애플리케이션
- 레이블이 지정된 고품질 예제를 수집하는 작업에 비용이 많이 들거나 해당 작업이 실용적이지 않은 경우

최상의 사용 사례

RFT는 출력 품질을 객관적으로 측정할 수 있지만 최적의 응답을 미리 정의하기 어려운 도메인에서 뛰어나습니다.

- 수학적 문제 해결 및 코드 생성
- 과학적 추론 및 정형 데이터 분석
- 단계별 추론 또는 멀티턴 문제 해결이 필요한 태스크
- 여러 목표(정확도, 효율성, 스타일)의 균형을 맞추는 애플리케이션
- 실행 결과 또는 성능 지표를 통해 프로그래밍 방식으로 성공을 확인할 수 있는 시나리오

지원되는 모델

Nova Lite 2.0

데이터 형식 개요

RFT 훈련 데이터는 OpenAI 강화 미세 조정 [형식](#)을 따라야 합니다. 각 훈련 예제는 다음을 포함하는 JSON 객체입니다.

- system 및 user 역할을 사용하는 대화 턴을 포함하는 messages 배열
- 보상 계산에 대한 평가 기준 또는 예상 출력이 포함된 reference_answer 필드

현재 제한 사항

- 텍스트 전용

데이터 형식 예제

각 예제는 JSONL 파일에서 한 줄에 있어야 하며 한 줄에 하나의 JSON 객체가 있어야 합니다.

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
}
```

reference_answer 필드에는 보상 함수가 모델 응답 점수를 지정하는 데 사용하는 평가 기준 또는 예상 출력이 포함되어 있습니다. 구조화된 출력으로 제한되지 않습니다. 보상 함수가 품질을 평가하는 데 도움이 되는 모든 형식을 포함할 수 있습니다.

데이터세트 크기 권장 사항

시작점

- 최소 100개의 훈련 예제
- 최소 100개의 평가 예제

평가 우선 접근 방식

대규모 RFT 훈련에 투자하기 전에 모델의 기준 성능을 평가합니다.

- 높은 성능(> 95% 보상) - RFT가 불필요할 수 있음 - 모델이 이미 잘 작동함
- 매우 낮은 성능(0% 보상) - 먼저 SFT로 전환하여 기본 기능을 설정함
- 중간 성능 - RFT가 적절할 가능성이 큼

작은 데이터세트로 시작하면 다음이 가능합니다.

- 보상 함수에 버그가 없는지 검증
- RFT가 사용 사례에 적합한 접근 방식인지 확인
- 조기에 문제 식별 및 해결
- 스케일 업하기 전에 워크플로 테스트

검증 후에 더 큰 데이터세트로 확장하여 성능을 더욱 개선할 수 있습니다.

효과적인 훈련 데이터의 특성

명확성 및 일관성

좋은 RFT 예제에는 여러 모델 출력에서 정확한 보상을 계산할 수 있는 명확하고 모호하지 않은 입력 데이터가 필요합니다. 다음을 포함하여 데이터에서 노이즈를 방지합니다.

- 일관되지 않은 형식 지정
- 모순되는 레이블 또는 지침
- 모호한 프롬프트
- 참조 답변 충돌

모호할 경우 훈련 프로세스에서 오해가 발생하고 모델이 의도하지 않은 동작을 학습하게 됩니다.

다양성

데이터세트는 강력한 실제 성능을 보장하기 위해 프로덕션 사용 사례의 완전한 다양성을 캡처해야 합니다. 포함:

- 여러 입력 형식 및 엡지 케이스
- 로그 및 사용자 분석의 실제 프로덕션 사용 패턴 매핑
- 사용자 유형, 지리적 리전 및 계절적 변형을 고려하는 샘플
- 간단한 문제부터 복잡한 문제까지 난이도 포함

보상 함수 고려 사항

효율적인 훈련을 위해 보상 함수를 설계합니다.

- 분이 아닌 초 단위 내 실행
- Lambda를 사용하여 효과적으로 병렬 처리
- 일관되고 신뢰할 수 있는 점수 반환
- 여러 유형의 모델 출력을 정상적으로 처리

빠르고 확장 가능한 보상 함수를 사용하면 빠른 반복과 비용 효율적인 실험이 가능합니다.

추가 속성

RFT 데이터 형식은 핵심 스키마 요구 사항(messages 및 reference_answer) 이외에도 사용자 지정 필드를 지원합니다. 이러한 유연성을 통해 적절한 평가를 위해 보상 함수에 필요한 데이터를 더 추가할 수 있습니다.

Note

레시피에서 이를 구성할 필요는 없습니다. 데이터 형식은 내재적으로 추가 필드를 지원합니다. 훈련 데이터 JSON에 포함하기만 하면 metadata 필드의 보상 함수로 전달됩니다.

공통 추가 속성

메타데이터 필드 예제:

- task_id - 추적을 위한 고유 식별자
- difficulty_level - 문제 복잡성 지표
- domain - 주제 영역 또는 카테고리
- expected_reasoning_steps - 솔루션에서 단계 수

추가 속성이 있는 예제

```
{
  "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
}

```

이러한 추가 필드는 평가 중에 보상 함수에 전달되므로 특정 사용 사례에 맞게 조정된 정교한 점수 매기기 로직이 가능합니다.

훈련 구성

샘플 레시피

```

# 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)

```

평가형 LLM을 사용하는 RFT 훈련

개요

대규모 언어 모델(LLM)은 강화 미세 조정(RFT) 워크플로의 평가자 역할로 더 많이 사용되고 있으며, 모델 최적화를 안내하는 자동화된 보상 신호를 제공합니다. 이 접근 방식에서 LLM은 정확성, 품질, 스

타일 준수 또는 시맨틱 동등성 평가와 같은 지정된 기준에 따라 모델 출력을 평가하고 강화 학습 프로세스를 주도하는 보상을 지정합니다.

이는 여러 표현(예: '1/3', '0.333', '삼분의 일')의 시맨틱이 동등한지 확인하거나 일관성 및 관련성과 같은 미묘한 품질을 평가하는 등 프로그래밍 방식으로 정의하기 어려운 태스크에 특히 유용합니다. LLM 기반 평가를 보상 함수로 사용하면 광범위한 인적 주석 없이도 RFT 규모를 복잡한 도메인으로 조정할 수 있으므로 기존 정렬 문제를 넘어 다양한 사용 사례에서 모델을 빠르게 반복하고 지속적으로 개선할 수 있습니다.

추론 모드 선택

사용 가능한 모드

- none - 추론 없음(reasoning_effort 필드 생략)
- low - 최소한의 추론 오버헤드
- high - 최대 추론 기능(reasoning_effort를 지정할 때 기본값)

Note

RFT에는 중간 옵션이 없습니다. 구성에 reasoning_effort 필드가 없으면 추론이 비활성화됩니다. 추론이 활성화된 경우 확장된 추론 출력을 수용하려면 max_new_tokens를 32,768로 설정해야 합니다.

각 모드를 사용해야 하는 경우

다음과 같은 경우 높은 수준의 추론을 사용합니다.

- 복잡한 분석 태스크
- 수학적 문제 해결
- 여러 단계의 논리적 연역
- 단계별 사고가 가치를 더하는 태스크

다음과 같은 경우에 none(reasoning_effort) 또는 낮은 수준의 추론을 사용합니다.

- 단순한 사실적 쿼리
- 직접 분류

- 속도 및 비용 최적화
- 간단한 질문과 답변

비용 및 성능의 장단점

추론 모드의 노력이 높아질수록 다음이 증가합니다.

- 훈련 시간 및 비용
- 추론 지연 시간 및 비용
- 복잡한 추론 태스크에 대한 모델 기능

LLM 판단 검증

프로덕션 환경에서 평가형 LLM을 배포하기 전에 평가 모델의 평가가 사람의 평가와 일치하는지 확인합니다. 여기에는 다음이 포함됩니다.

- 태스크의 대표 샘플에서 LLM 평가와 인적 평가자 간 합의 비율 측정
- 사람과 LLM의 합의가 사람 간 합의 비율을 충족하거나 초과하도록 보장
- 평가 모델의 잠재적 편향 식별
- 보상 신호가 모델을 의도한 방향으로 안내한다는 확신 구축

이 검증 단계는 자동화된 평가 프로세스가 프로덕션 품질 기준을 충족하는 모델을 생성하는 데 도움이 됩니다.

LLM 평가에 대한 Lambda 구성

평가형 LLM 사용은 검증 가능한 보상을 통한 강화 학습(RLVR)에 Lambda 함수를 사용하는 확장입니다. Lambda 함수 내에서 Amazon Bedrock에 호스팅되는 모델 중 하나를 직접 호출합니다.

중요한 구성 요구 사항:

구성	요구 사항	세부 정보
Amazon Bedrock 처리량	충분한 할당량	사용된 Amazon Bedrock 모델의 처리량 할당량이 훈련 워크로드에 충분하도록 보장

구성	요구 사항	세부 정보
Lambda 제한 시간	연장된 제한 시간	최대 15분으로 Lambda 함수 제한 시간을 구성합니다. 기본 설정은 3초이며, 이는 Amazon Bedrock 모델 응답에 충분하지 않음
Lambda 동시성	동시성 증가	Lambda는 훈련 중에 병렬로 간접 호출됩니다. 동시성을 늘려 사용 가능한 처리량 극대화
레시피 구성	Lambda 설정 일치	동시성 제한은 레시피에서 구성해야 함

작업 생성 및 실행

훈련 작업 시작

SageMaker 훈련 작업 노트북 템플릿(<https://docs.aws.amazon.com/sagemaker/latest/dg/nova-fine-tuning-training-job.html#nova-model-training-jobs-notebook>)을 사용합니다.

인스턴스 요구 사항

컨테이너는 전체 순위 훈련 및 LoRA 훈련을 모두 지원합니다.

- LoRA 훈련 - 2/4/6/8 × p5.48xlarge 또는 p5en.48xlarge 인스턴스
- 전체 순위 훈련 - 2/4/6/8 × p5.48xlarge 인스턴스(필수)

훈련 모니터링

훈련 로그에는 각 단계에서 포괄적인 지표가 포함됩니다. 주요 지표 카테고리:

보상 지표

- critic/rewards/mean, critic/rewards/max, critic/rewards/min – 보상 배포
- val-score/rewards/mean@1 - 검증 보상

모델 동작

- actor/entropy – 정책 변형(높은 값 = 더 탐색적)

훈련 상태

- actor/pg_loss - 정책 그라데이션 손실
- actor/pg_clipfrac - 잘린 업데이트 빈도
- actor/grad_norm - 그라데이션 크기

응답 특성

- prompt_length/mean, prompt_length/max, prompt_length/min - 입력 토큰 통계
- response_length/mean, response_length/max, response_length/min - 출력 토큰 통계
- response/aborted_ratio - 불완전 생성 속도(0 = 모두 완료됨)

성능

- perf/throughput - 훈련 처리량
- perf/time_per_step - 훈련 단계당 시간
- timing_per_token_ms/* - 토큰당 처리 시간

리소스 사용량

- perf/max_memory_allocated_gb, perf/max_memory_reserved_gb - GPU 메모리
- perf/cpu_memory_used_gb - CPU 메모리

미세 조정 모델 사용

훈련이 완료되면 최종 모델 체크포인트가 지정된 출력 위치에 저장됩니다. 체크포인트 경로는 다음 위치에서 사용할 수 있습니다.

- 훈련 로그
- 출력 Amazon S3 위치에서 manifest.json 파일(노트북의 output_s3_uri에 의해 정의)

제한 사항 및 모범 사례

제한 사항

- Lambda 제한 시간 - 보상 함수는 15분 이내에 완료되어야 함(불필요한 프로세스를 방지하고 비용을 관리함)

- 싱글턴만 - 멀티턴 대화는 지원되지 않음
- 데이터 요구 사항 - 다양성이 충분해야 함, 희소 보상에 어려움(5% 미만의 긍정적인 예제)
- 컴퓨팅 비용 - 지도 미세 조정보다 비용이 많이 발생함
- 멀티모달 데이터 없음 - 텍스트 데이터 유형만 지원됨

모범 사례

작게 시작

- 100~200개의 예제로 시작
- 보상 함수 정확성 검증
- 결과를 기반으로 점진적으로 규모 조정

사전 훈련 평가

- RFT 이전에 기존 모델 성능 테스트
- 보상이 일관되게 0%인 경우 먼저 SFT를 사용하여 기본 기능 설정
- 보상이 95%를 초과하는 경우 RFT가 필요하지 않을 수 있음

훈련 모니터링

- 평균 보상 점수 및 분포 추적
- 과적합 감시(훈련 보상은 증가하지만, 검증 보상은 감소함)
- 우려되는 패턴을 찾습니다.
 - 0.15 미만으로 보상 정체
 - 시간 경과에 따른 보상 분산 증가
 - 검증 성능 저하

보상 함수 최적화

- 분이 아닌 초 단위 내 실행
- 외부 API 직접 호출 최소화
- 효율적인 알고리즘 사용
- 적절한 오류 처리 구현

- Lambda의 병렬 조정 활용

반복 전략

보상이 개선되지 않는 경우:

- 보상 함수 설계 조정
- 데이터세트 다양성 증가
- 대표성이 강한 예제 추가
- 보상 신호가 명확하고 일관된지 확인

고급 기능: Nova Forge

표준 RFT 제한 사항을 넘어 고급 기능이 필요한 사용자의 경우 Nova Forge를 유료 구독 서비스 오퍼링으로 사용할 수 있습니다.

- 멀티턴 대화 지원
- 실행 시간이 15분을 초과하는 보상 함수
- 추가 알고리즘 및 조정 옵션
- 사용자 지정 훈련 레시피 수정
- 첨단 AI 기술

Nova Forge는 SageMaker HyperPod에서 실행되며 엔터프라이즈 고객이 자체 프론티어 모델을 빌드할 수 있도록 설계되었습니다.

유용한 명령 및 팁

[관찰성 스크립트](#) 모음을 사용하여 훈련 작업의 상태 및 진행 상황을 모니터링할 수 있습니다.

사용 가능한 스크립트는 다음과 같습니다.

- 훈련 작업 상태 업데이트에 대한 이메일 알림 활성화
- 작업 구성을 기반으로 훈련 시간 추정치 확보
- 진행 중인 작업에 대한 훈련 예상 시간의 근사치 확보

설치

Note

다음 스크립트를 사용하기 전에 AWS 자격 증명을 새로 고쳐야 합니다.

```
pip install boto3
git clone https://github.com/aws-samples/amazon-nova-samples.git
cd amazon-nova-samples/customization/SageMakerUilts/SageMakerJobsMonitoring/
```

기본 사용법

```
# 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
```

자세한 내용 및 예제는 [여기](#)를 참조하세요.



여러 반복에서 진행 상황 모니터링

MLflow를 통해 지표를 추적할 수 있습니다.

Nova 사용자 지정 - SageMaker HyperPod에 대한 MLFlow 설정

SageMaker HyperPod 환경이 지표를 MLFlow에 출력하도록 하려면 몇 가지 추가 설정을 수행해야 합니다.

1. Amazon SageMaker AI 열기
2. SageMaker Studio 선택
 - a. 이미 생성된 프로필이 있는 경우 'Studio 열기' 선택
 - b. 프로필이 생성되지 않은 경우 'SageMaker 도메인 생성'을 선택하여 설정
3. MLFlow를 선택하세요. 생성된 MLFlow 앱이 없는 경우 'MLFlow 앱 생성'을 선택하세요.
4. ML Flow 앱에서 복사/붙여넣기 버튼 또는 '세부 정보 보기' 메뉴 항목을 클릭하여 ARN을 가져오세요. 훈련 작업을 제출할 때 이 정보가 필요합니다.



5. HyperPod 클러스터 실행 역할에서 다음 정책을 추가하세요. 그러면 HyperPod 클러스터가 MLFlow API를 직접 호출하여 지표를 게시할 수 있습니다.

```
{
  "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": "*"
    }
  ]
}
```

```
    }
  ]
}
```

CLI를 통해 작업 제출

명령줄 또는 레시피 yaml에서 4개의 새 재정의 파라미터를 지정합니다.

1. `mlflow_tracking_uri`: MLFlow 앱의 ARN
2. `mlflow_experiment_name`: 실험에 대한 이 실행의 이름
3. `mlflow_experiment_name`: 지표가 MLFlow에 저장되는 실험 이름
4. `mlflow_run_name`: 이 실험의 이름

명령줄

```
--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"
```

SageMaker Studio UI를 통해 작업 제출

MLFlow 통합은 SageMaker Studio UI 환경에 이미 빌드되어 있습니다. 훈련 작업을 제출할 때 사용할 MLFlow 앱 인스턴스를 표시하기만 하면 됩니다.

1. SageMaker Studio에서 모델 > Nova 2.0 Lite > 사용자 지정 > UI로 사용자 지정으로 이동하세요.

2. 고급 구성 섹션 확장

3. 훈련 지표를 전송할 MLflow 앱을 선택하세요. 여기에서 실험 이름과 실험 실행을 설정할 수도 있습니다.

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

AWS AWS CLI를 통해 작업 제출

AWS AWS CLI를 사용하는 경우 MLflow 앱을 생성하고 이를 훈련 작업 API 요청에 대한 입력으로 전달해야 합니다.

```
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)
```

MLflow 앱 생성

Studio UI 사용: Studio UI를 통해 훈련 작업을 생성하는 경우 기본 MLflow 앱이 자동으로 생성되고 고급 옵션에서 기본적으로 선택됩니다.

CLI 사용: CLI를 사용하는 경우 MLflow 앱을 생성하고 이를 훈련 작업 API 요청에 대한 입력으로 전달해야 합니다.

```
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)
```

MLflow 앱에 액세스

CLI 사용: 미리 서명된 URL을 생성하여 MLflow 앱 UI에 액세스합니다.

```
aws sagemaker create-presigned-mlflow-app-url \
  --arn $mlflow_app_arn \
  --region $region \
  --output text
```

Studio UI 사용: Studio UI는 MLflow에 저장된 주요 지표를 표시하고 MLflow 앱 UI에 대한 링크를 제공합니다.

추적할 주요 지표

여러 반복에서 이러한 지표를 모니터링하여 개선 사항을 평가하고 작업 진행 상황을 추적합니다.

SFT의 경우

- 훈련 손실 곡선
- 소비된 샘플 수 및 샘플 처리 시간
- 홀드아웃 테스트 세트의 성능 정확도
- 형식 규정 준수(예: 유효한 JSON 출력 비율)
- 도메인별 평가 데이터의 퍼플렉시티

RFT의 경우

- 훈련 대비 평균 보상 점수
- 보상 분포(높은 보상 응답의 백분율)
- 검증 보상 추세(과적합 감시)
- 태스크별 성공률(예: 코드 실행 통과 비율, 수학 문제 정확도)

일반

- 반복 간 벤치마크 성능 델타
- 대표 샘플에 대한 인적 평가 점수
- 프로덕션 지표(반복적으로 배포하는 경우)

중지 시점 결정

다음과 같은 경우 반복을 중지합니다.

- 성능 정체: 추가 훈련으로도 대상 지표가 더 이상 유의미하게 개선되지 않음
- 기법 전환 지원: 한 기법이 정체된 경우 성능 상한을 깨뜨리려면 전환(예: SFT → RFT → SFT) 시도
- 목표 지표 달성: 성공 기준을 충족함
- 회귀 감지: 새 반복은 성능을 저하시킴(아래 롤백 절차 참조)

자세한 평가 절차는 평가 섹션을 참조하세요.

SageMaker AI로 훈련된 모델 평가

평가 프로세스의 목적은 훈련된 모델의 성능을 벤치마크 또는 사용자 지정 데이터세트와 비교하여 평가하는 것입니다. 평가 프로세스에는 일반적으로 훈련된 모델을 가리키는 평가 레시피를 생성하고, 평가 데이터세트와 지표를 지정하며, 별도의 평가 작업을 제출하고, 표준 벤치마크 또는 사용자 지정 데이터에 대해 성능을 평가하는 단계가 포함됩니다. 평가 프로세스는 Amazon S3 버킷에 저장된 성능 지표를 출력합니다.

Note

이 주제에 설명된 평가 프로세스는 오프라인 프로세스입니다. 모델은 실시간 또는 실제 사용자 상호 작용을 통해 평가되지 않고 미리 정의된 답변이 있는 고정 벤치마크를 기준으로 테스트됨

니다. 실시간 평가를 위해서는, 모델을 Amazon Bedrock에 배포한 후 [Amazon Bedrock](#) 런타임 API를 직접적으로 호출하여 테스트할 수 있습니다.

주제

- [사전 조건](#)
- [사용 가능한 벤치마크 태스크](#)
- [평가 관련 구성](#)
- [평가 훈련 작업 실행](#)
- [평가 결과 평가 및 분석](#)
- [평가 모범 사례 및 문제 해결](#)
- [사용 가능한 하위 태스크](#)
- [추론 모델 평가](#)
- [RFT 평가](#)
- [보상 함수 구현](#)

사전 조건

평가 훈련 작업을 시작하기 전에 다음 사항을 확인하세요.

- 성능을 평가하려는, SageMaker AI로 훈련된 Amazon Nova 모델.
- 평가를 위한 기본 Amazon Nova 레시피. 자세한 내용은 [???](#) 섹션을 참조하세요.

사용 가능한 벤치마크 태스크

Amazon Nova에 대한 SageMaker AI 모델 평가 기능을 사용하여 벤치마크 지표를 계산하는 방법을 보여주는 샘플 코드 패키지를 사용할 수 있습니다. 코드 패키지에 액세스하려면 [sample-Nova-lighteval-custom-task](#)를 참조하세요.

다음은 사용 가능한 업계 표준 벤치마크 목록입니다. eval_task 파라미터에 다음 벤치마크를 지정할 수 있습니다.

모델 평가에 사용할 수 있는 벤치마크

벤치마크	양식	설명	Metrics	전략	하위 태스크 사용 가능
mmlu	텍스트	다중 태스크 언어 이해 - 57개 주제에 걸친 지식을 테스트합니다.	정확도	zs_cot	예
mmlu_pro	텍스트	MMLU - 전문 하위 세트 - 법률, 의학, 회계, 엔지니어링 등 전문 분야에 중점을 둡니다.	정확도	zs_cot	아니요
bbh	텍스트	고급 추론 태스크 - 높은 수준의 인지 능력과 문제 해결 능력을 테스트하는 도전적 문제의 모음입니다.	정확도	fs_cot	예
gpqa	텍스트	일반 물리학 질문 응답 - 물리 개념 이해와 관련 문제 해결 능력을 평가합니다.	정확도	zs_cot	아니요
math	텍스트	수학적 문제 해결 - 대수학, 미적분학, 문	exact_match	zs_cot	예

벤치마크	양식	설명	Metrics	전략	하위 태스크 사용 가능
		장제 문제 등 여러 주제에 서 수학적 추론 능력을 측정합니다.			
strong_reject	텍스트	품질 관리 태스크 - 부적절하거나 유해하거나 잘못된 콘텐츠를 감지하고 거부하는 모델의 능력을 테스트합니다.	deflection	zs	예
ifeval	텍스트	지침 준수 평가 - 모델이 주어진 지침을 얼마나 정확하게 따르고 요구 조건에 맞게 태스크를 완료하는지 측정합니다.	정확도	zs	아니요

벤치마크	양식	설명	Metrics	전략	하위 태스크 사용 가능
gen_qa	멀티모달(이미지)	사용자 지정 데이터세트 평가 - 사용자가 자체 데이터 세트를 가져와서 벤치마킹을 수행하고, ROUGE 및 BLEU와 같은 지표를 사용하여 모델 출력을 참조 답변과 비교합니다. gen_qa는 Amazon Nova Lite 또는 Amazon Nova Pro 기반 모델에 대한 이미지 추론을 지원합니다. 또한 Bring-Your-Own Metrics lambda를 지원합니다. (RFT 평가의 경우 RFT 평가 레시피를 사용하세요.)	모두	gen_qa	아니요

벤치마크	양식	설명	Metrics	전략	하위 태스크 사용 가능
mmmu	멀티모달	대규모 다분야 멀티모달 이해(MMMU) - 30개 학문 분야의 객관식 및 서술형 문제로 구성된 대학 수준 벤치마크입니다.	정확도	zs_cot	예
llm_judge	텍스트	평가형 LLM 선호도 비교 - Nova Judge 모델을 사용하여 프롬프트에 대한 응답 쌍(A와 B)을 비교하고, B가 A보다 선호될 확률을 계산합니다.	모두	judge	아니요

벤치마크	양식	설명	Metrics	전략	하위 태스크 사용 가능
mm_llm_judge	멀티모달(이미지)	이 새로운 벤치마크는 위의 텍스트 기반 llm_judge와 동일하게 동작합니다. 유일한 차이는 이미지 추론을 지원한다는 점입니다.	모두	judge	아니요

벤치마크	양식	설명	Metrics	전략	하위 태스크 사용 가능
rubric_llm_judge	텍스트	Rubric Judge는 Nova 2.0 Lite에 빌드된 향상된 평가형 LLM 평가 모델입니다. 기본 설정 결정만 제공하는 원래 평가 모델 과 달리 Rubric Judge는 각 프롬프트에 맞게 조정된 사용자 지정 평가 기준을 동적으로 생성하고 여러 차원에 세분화된 점수를 할당합니다.	모두	judge	아니요
aime_2024	텍스트	AIME 2024 - 고급 수학 추론 및 문제 해결을 테스트하는 미국 초대 수학 검사 문제	exact_match	zs_cot	아니요

벤치마크	양식	설명	Metrics	전략	하위 태스크 사용 가능
calendar_scheduling	텍스트	Natural Plan - 여러 사람을 대상으로 여러 날에 걸쳐 회의를 예약할 수 있는 일정 예약 태스크 테스트 계획 기능	exact_match	fs	아니요
humaneval	텍스트	HumanEval - 대규모 언어 모델의 코드 생성 능력을 평가하도록 설계된 벤치마크 데이터 세트입니다.	pass@1	zs	아니요

평가 관련 구성

다음은 레시피의 주요 구성 요소에 대한 분석과 이를 사용 사례에 맞게 수정하는 방법에 대한 지침입니다.

레시피 이해 및 수정

일반 실행 구성

```
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:** 평가 작업에 대한 설명이 포함된 이름입니다.
- **model_type:** 사용할 Nova 모델 변형을 지정합니다. 이 필드는 수동으로 수정하지 마세요. 옵션에는 다음이 포함됩니다.
 - 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:** 기본 모델 경로 또는 훈련 후 체크포인트의 S3 경로입니다. 옵션에는 다음이 포함됩니다.
 - nova-micro/prod
 - nova-lite/prod
 - nova-pro/prod
 - nova-lite-2/prod
 - 훈련 후 체크포인트 경로의 S3 경로(s3:customer-escrow-111122223333-smtj-
<unique_id>/<training_run_name>)

Note

훈련 후 모델 평가

Nova SFT 훈련 작업 후 훈련 후 모델을 평가하려면 훈련 작업을 성공적으로 실행한 후 다음 단계를 따르세요. 훈련 로그 끝에 "Training is complete"라는 로그 메시지가 표시됩니다. 또한 출력 버킷에서 체크포인트 위치가 포함된 manifest.json 파일을 찾을 수 있습니다. 이 파일은 출력 S3 위치의 output.tar.gz 파일 내에 있습니다. 평가를 진행하려면 레시피 구성에서 이 체크포인트를 run.model_name_or_path 값으로 설정하세요.

- **replica:** 분산 추론(여러 노드에서 추론 실행)에 사용할 컴퓨팅 인스턴스 수. 다중 노드 추론을 활성화하려면 replica > 1을 설정합니다. 그러면 평가 속도가 빨라집니다. instance_count 및 replica를 모두 지정하면 instance_count가 우선합니다. 여러 복제본은 SageMaker HyperPod가 아닌 SageMaker AI 훈련 작업에만 적용됩니다.
- **data_s3_path:** 입력 데이터세트 Amazon S3 경로입니다. 이 필드는 필수이지만 항상 비워 두어야 합니다.
- **mlflow_tracking_uri:** (선택 사항) MLflow 추적 서버의 위치(SMHP에만 필요)

- `mlflow_experiment_name`: (선택 사항) 관련 ML 실행을 그룹화하는 실험의 이름
- `mlflow_run_name`: (선택 사항) 실험 내 특정 훈련 실행의 사용자 지정 이름

평가 구성

```
evaluation:
  task: mmlu
  strategy: zs_cot
  subtask: abstract_algebra
  metric: accuracy
```

- `task`: 사용할 평가 벤치마크 또는 태스크를 지정합니다. 지원되는 태스크에는 다음이 포함됩니다.
 - `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`: 평가 접근 방식을 정의합니다.
 - `zs_cot`: 제로샷 생각의 사슬 - 명시적인 예시 없이, 단계별 추론을 수행하도록 대형 언어 모델에 지시하는 접근 방식입니다.
 - `fs_cot`: 퓨샷 생각의 사슬 - 모델에 새 문제를 해결하도록 요청하기 전에 단계별 추론의 몇 가지 예시를 제공하는 접근 방식입니다.
 - `zs`: 제로샷 - 사전 훈련 예시 없이 문제를 해결하는 접근 방식입니다.

- `gen_qa`: 사용자 제공 데이터세트에 특화된 전략입니다.
- `judge`: Nova LLM as Judge 및 `mm_llm_judge`에 특정한 전략.
- `subtask`: 선택 사항입니다. 평가 태스크의 특정 구성 요소입니다. 사용 가능한 하위 태스크에 대한 전체 목록은 [???](#) 섹션을 참조하세요.
- 사용 가능한 벤치마크 태스크에서 지원되는 하위 태스크를 확인합니다.
- 하위 태스크 벤치마크가 없는 경우 이 필드를 제거해야 합니다.
- `metric`: 사용할 평가 지표입니다.
 - `accuracy`: 정답 비율입니다.
 - `exact_match`: math 벤치마크의 경우 입력 예측 문자열이 참조와 정확히 일치하는 비율을 반환합니다.
 - `deflection`: strong reject 벤치마크의 경우 기본 모델에 대한 상대 편향과 중요도 지표의 차이를 반환합니다.
 - `all`:

`gen_qa`의 사용자 제공 데이터세트 벤치마크의 경우 다음 지표를 반환합니다.

- `rouge1`: 생성된 텍스트와 참조 텍스트 간의 유니그램(단일 단어) 중복을 측정합니다.
- `rouge2`: 생성된 텍스트와 참조 텍스트 간의 바이그램(2개 연속 단어) 중복을 측정합니다.
- `rougeL`: 텍스트 간에 가장 긴 공통 부분 수열을 측정하며, 일치 항목 간의 간격을 허용합니다.
- `exact_match`: 생성된 텍스트가 문자별로 참조 텍스트와 정확히 일치하는지 여부를 나타내는 이진 점수(0 또는 1)입니다.
- `quasi_exact_match`: `exact_match`와 유사하지만 일반적으로 대소문자, 구두점 및 공백 차이를 무시하는 더 관대한 일치 방식입니다.
- `f1_score`: 정밀도와 재현율의 조화 평균으로, 예측된 답변과 참조 답변 간의 단어 중복을 측정합니다.
- `f1_score_quasi`: `f1_score`와 유사하지만 사소한 차이를 무시하는 정규화된 텍스트 비교를 사용하는 더 관대한 일치 방식입니다.
- `bleu`: 생성된 텍스트와 참조 텍스트 간의 n그램 일치 정밀도를 측정하며, 일반적으로 번역 평가에 사용됩니다.

`llm_judge` 및 `mm_llm_judge`의 경우 자체 제공 데이터세트 벤치마크를 가져오고 다음 지표를 반환합니다.

- `a_scores`: 순방향 및 역방향 평가 패스에서 `response_A`가 승리한 횟수입니다.

- 평가
- `a_scores_stderr`: 쌍별 판단에서 `response_A_scores`의 표준 오차입니다.

- `b_scores`: 순방향 및 역방향 평가 패스에서 `response_B`가 승리한 횟수를 측정합니다.
- `a_scores_stderr`: 쌍별 판단에서 `response_B_scores`의 표준 오차입니다.
- `ties`: `response_A`와 `response_B`가 동일한 것으로 평가되는 판단 수입니다.
- `ties_stderr`: 쌍별 판단에서 `ties`의 표준 오차입니다.
- `inference_error`: 올바르게 평가되지 못한 판단 수입니다.
- `score`: `response_B`에 대한 순방향 및 역방향 패스의 승리 횟수에 기반한 집계 점수입니다.
- `score_stderr`: `response_B`에 대한 순방향 및 역방향 패스의 승리 횟수에 기반한 집계 점수입니다.
- `inference_error_stderr`: 쌍별 판단에서 집계 점수의 표준 오차입니다.
- `winrate`: Bradley-Terry 확률을 사용하여 계산된, `response_B`가 `response_A`보다 선호될 확률입니다.
- `lower_rate`: 부트스트랩 샘플링에서 추정된 승률의 하한(2.5번째 백분위수)입니다.
- `upper_rate`: 부트스트랩 샘플링에서 추정된 승률의 상한(97.5번째 백분위수)입니다.

추론 구성(선택 사항)

```
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`: 생성할 최대 토큰 수입니다. 정수여야 합니다. (LLM Judge에는 사용할 수 없음)
- `top_k`: 고려할 확률이 가장 높은 토큰의 수입니다. 정수여야 합니다.
- `top_p`: 토큰 샘플링을 위한 누적 확률 임계값입니다. 1.0에서 0.0 사이의 부동 소수점 수여야 합니다.
- `temperature`: 토큰 선택의 무작위성(값이 높을수록 더 무작위). 결과를 결정론적으로 만들려면 0으로 유지합니다. 부동 소수점 수 유형, 최소값은 0입니다.
- `top_logprobs`: 추론 응답에서 반환할 상위 logprobs 수. 이 값은 0~20의 정수여야 합니다. Logprobs에는 메시지 콘텐츠에서 반환된 각 출력 토큰의 고려된 출력 토큰 수와 로그 확률이 포함됩니다.

- `reasoning_effort`: 추론 가능 모델의 추론 동작을 제어합니다. `model_type`이 추론 가능 모델 (현재 `amazon.nova-2-lite-v1:0:256k`)을 지정하는 경우에만 `reasoning_effort`를 설정합니다. 사용 가능한 옵션은 `null`(설정하지 않은 경우 기본값, 추론 비활성화), `low` 또는 `high`입니다.

로그 확률 출력 형식

`top_logprobs`가 추론 설정에서 구성된 경우 평가 출력에는 parquet 파일에 토큰 수준 로그 확률이 포함됩니다. 각 토큰 위치에는 로그 확률이 다음과 같이 구성된 상위 후보 토큰의 사전이 포함되어 있습니다.

```
{
  "Ġint": {"logprob_value": -17.8125, "decoded_value": " int"},
  "Ġthe": {"logprob_value": -2.345, "decoded_value": " the"}
}
```

각 토큰 항목에는 다음이 포함됩니다.

- `logprob_value`: 토큰의 로그 확률 값
- `decoded_value`: 사람이 읽을 수 있는 디코딩된 토큰 문자열 표현

원시 토큰화 토큰은 고유성을 보장하기 위한 사전 키로 사용되는 반면, `decoded_value`는 사람이 읽을 수 있는 해석을 제공합니다.

평가 레시피 예시

Amazon Nova는 네 가지 유형의 평가 레시피를 제공합니다. 모든 레시피는 [SageMaker HyperPod 레시피 GitHub 리포지토리](#)에서 사용할 수 있습니다.

일반 텍스트 벤치마크 레시피

이러한 레시피를 사용하면 광범위한 텍스트 전용 벤치마크 모음 전반에서 Amazon Nova 모델의 기본 기능을 평가할 수 있습니다.

레시피 형식: `xxx_general_text_benchmark_eval.yaml`.

사용자 제공 데이터세트 벤치마크 레시피

이러한 레시피를 사용하면 벤치마킹을 위한 자체 데이터세트를 가져와서 다양한 유형의 지표를 사용하여 모델 출력을 참조 답변과 비교할 수 있습니다.

레시피 형식: `xxx_ bring_your_own_dataset_eval.yaml`.

사용자 제공 데이터세트 요구 사항

파일 형식:

- 평가 예시가 포함된 단일 `gen_qa.jsonl` 파일입니다. 파일 이름은 `gen_qa.jsonl`과 정확히 일치해야 합니다.
- 데이터세트는 SageMaker AI 훈련 작업에서 액세스할 수 있는 S3 위치에 업로드해야 합니다.
- 파일은 일반 Q&A 데이터세트에 필요한 스키마 형식을 따라야 합니다.

스키마 형식 요구 사항 - `.jsonl` 파일의 각 줄은 다음 필드가 있는 JSON 객체여야 합니다.

- 필수 필드.

`query`: 답변이 필요한 질문 또는 지침이 포함된 문자열입니다.

`response`: 예상 모델 출력을 포함하는 문자열입니다.

- 선택 필드.

`system`: 쿼리를 처리하기 전에 AI 모델의 동작, 역할 또는 특성을 설정하는 시스템 프롬프트가 포함된 문자열입니다.

`images`: 데이터 속성(Base64로 인코딩된 이미지 문자열)이 있는 객체 목록을 포함하는 배열.

`metadata`: 태그 지정을 위해 항목과 연결된 메타데이터를 포함하는 문자열.

입력 예

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

```

사용자 지정 데이터셋을 사용하려면 기존 구성을 변경하지 않으면서 다음 필수 필드를 추가하여 평가 레시피를 수정합니다.

```

evaluation:
  task: gen_qa
  strategy: gen_qa
  metric: all

```

제한 사항

- 평가당 하나의 .jsonl 파일만 허용됩니다.
- 파일은 정의된 스키마를 엄격하게 따라야 합니다.

자체 지표 가져오기

사용자 지정 사전 처리, 사후 처리 및 지표 기능을 사용하여 자체 지표를 가져와 모델 평가 워크플로를 완전히 사용자 지정할 수 있습니다. 사전 처리에서는 입력 데이터를 추론 서버로 보내기 전에 입력 데이터를 처리할 수 있으며, 사후 처리에서는 지표 계산을 사용자 지정하고 필요에 따라 사용자 지정 지표를 반환할 수 있습니다.

다음 단계에 따라 사용자 지정 평가 SDK로 자체 지표를 가져옵니다.

1. 아직 수행하지 않은 경우 먼저 AWS 계정에서 [AWS Lambda 함수를 생성](#)하세요.
2. [GitHub 리포지토리](#)에서 nova-custom-eval-layer.zip 파일을 다운로드하세요. 이 오픈 소스 Nova 사용자 지정 평가 SDK를 사용하여 사용자 지정 함수의 입력 및 출력 페이로드를 검증하고

훈련 중에 Nova의 자체 지표 가져오기 평가와 통합하기 위해 통합 인터페이스를 제공할 수 있습니다.

3. 다음 명령을 사용하여 사용자 지정 Lambda 계층을 업로드하세요.

```
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. 필수 AWS 계층(pydantic 종속성에 필요한 AWSLambdaPowertoolsPythonV3-python312-arm64)과 함께 Lambda 함수에 사용자 지정 계층으로 이 계층을 추가하세요.
5. 제공된 예제를 사용하여 Lambda 코드를 업데이트하고 필요에 따라 코드를 수정하세요. 이 예제 코드는 모델 평가를 위한 사전 처리 및 사후 처리 단계를 사용하여 Nova의 사용자 지정 평가를 위한 Lambda 함수를 생성합니다.

```
from nova_custom_evaluation_sdk.processors.decorators import preprocess,
    postprocess
from nova_custom_evaluation_sdk.lambda_handler import build_lambda_handler

@preprocess
def preprocessor(event: dict, context) -> dict:
    data = event.get('data', {})
    return {
        "statusCode": 200,
        "body": {
            "system": data.get("system"),
            "prompt": data.get("prompt", ""),
            "gold": data.get("gold", "")
        }
    }

@postprocess
def postprocessor(event: dict, context) -> dict:
    # data is already validated and extracted from event
    data = event.get('data', [])
    inference_output = data.get('inference_output', '')
    gold = data.get('gold', '')

    metrics = []
    inverted_accuracy = 0 if inference_output.lower() == gold.lower() else 1.0
    metrics.append({
        "metric": "inverted_accuracy_custom",
```

```

        "value": accuracy
    })

    # Add more metrics here

    return {
        "statusCode": 200,
        "body": metrics
    }

# Build Lambda handler
lambda_handler = build_lambda_handler(
    preprocessor=preprocessor,
    postprocessor=postprocessor
)

```

6. 평가 작업에 대한 액세스 권한을 Lambda에 부여하세요. 평가 작업에 지정된 실행 역할에 Lambda 함수를 간접 호출하는 정책이 포함되어 있는지 확인하세요. 다음은 예시 정책입니다.

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. Lambda 페이로드 스키마를 검토하세요. 다음 표에는 Lambda 요청 및 응답 스키마가 나열되어 있습니다. Nova 사용자 지정 평가 SDK를 사용하여 스키마를 검증할 수 있습니다.

	Lambda 요청 페이로드	Lambda 응답 페이로드
사전 처리 기	<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>
사후 처리 기	<pre> { "process_type": "postprocess", "data": { "prompt": "What is 2+2?", "inference_output": "2+2=4", "gold": "4" } } </pre>	<pre> { "statusCode": 200, "body": [{"metric": "accuracy", "value": 1.0}, {"metric": "f1_score", "value": 1.0}, {"metric": "exact_match", "value": 1},] } </pre>

	Lambda 요청 페이로드	Lambda 응답 페이로드
	<pre>} </pre>	<pre>{ "metric": "length_ratio", "value": 0.8 }</pre>

8. 레시피 파일을 수정하세요. 다음 예를 참고하세요

```
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`: 사전 처리 및 사후 처리를 담당하는 Lambda 함수의 Amazon 리소스 이름(ARN).
- `lambda_type`: 'custom_metrics' 또는 'rft'.
- `preprocessing`: 사용자 지정 사전 처리 작업의 활성화 여부.
- `postprocessing`: 사용자 지정 사후 처리 작업의 활성화 여부.
- `aggregation`: 기본 제공 집계 함수(유효한 옵션: min, max, average, sum).

제한 사항

- 자체 지표 가져오기는 텍스트 입력 데이터세트에만 적용됩니다.
- 멀티모달 입력 데이터세트는 지원되지 않습니다.
- 사전 처리 단계에서는 메타데이터 필드를 처리하지 않습니다.

평가형 Nova LLM 벤치마크 레시피

평가형 Nova LLM은 사용자 지정 데이터세트를 사용하여 한 모델의 응답 품질을 기준 모델의 응답과 비교하는 모델 평가 기능입니다. 프롬프트, 기준 응답 및 도전자 응답이 있는 데이터세트를 수락하고 Nova Judge 모델을 사용하여 쌍별 비교를 통해 [Bradley-Terry](#) 확률에 기반한 승률 지표를 제공합니다. 레시피 형식: `xxx_llm_judge_eval.yaml`.

Nova LLM 데이터세트 요구 사항

파일 형식:

- 평가 예시가 포함된 단일 `11m_judge.jsonl` 파일입니다. 파일 이름은 `11m_judge.jsonl`과 정확히 일치해야 합니다.
- 데이터세트는 SageMaker AI 훈련 작업에서 액세스할 수 있는 S3 위치에 업로드해야 합니다.
- 파일은 `11m_judge` 데이터세트에 필요한 스키마 형식을 따라야 합니다.
- 입력 데이터세트는 모든 레코드가 12k 컨텍스트 길이 미만인지 확인해야 합니다.

스키마 형식 - `.jsonl` 파일의 각 줄은 다음 필드가 있는 JSON 객체여야 합니다.

- 필수 필드:

`prompt`: 생성된 응답에 대한 프롬프트가 포함된 문자열입니다.

`response_A`: 기준 응답을 포함하는 문자열입니다.

`response_B`: 기준 응답과 비교할 대체 응답을 포함하는 문자열입니다.

입력 예

```
{
  "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."
}

```

사용자 지정 데이터셋을 사용하려면 다음 필수 필드를 포함하도록 평가 레시피를 수정합니다. 콘텐츠는 변경하지 마세요.

```

evaluation:
  task: llm_judge
  strategy: judge
  metric: all

```

제한 사항

- 평가당 하나의 .jsonl 파일만 허용됩니다.
- 파일은 정의된 스키마를 엄격하게 따라야 합니다.
- Nova Judge 모델은 micro/lite/pro 사양에서 동일합니다.
- (현재 사용자 지정 구분 기호는 지원되지 않습니다.)

멀티모달(이미지) 벤치마크 레시피에 대한 Nova 평가형 LLM

Nova MM_LLM Judge라고 하는 멀티모달에 대한 Nova LLM Judge(이미지)는 사용자 지정 데이터셋을 사용하여 한 모델의 응답 품질을 기준 모델의 응답과 비교하는 모델 평가 기능입니다. 프롬프트, 기준 응답, 도전자 응답, Base64로 인코딩된 문자열 양식의 이미지가 있는 데이터셋을 수락하고 Nova Judge 모델을 사용하여 페어별 비교를 통해 [Bradley-Terry](#) 확률에 기반한 승률 지표를 제공합니다. 레시피 형식: xxx_mm_llm_judge_eval.yaml.

Nova LLM 데이터셋 요구 사항

파일 형식:

- 평가 예시가 포함된 단일 mm_llm_judge.jsonl 파일입니다. 파일 이름은 정확히 llm_judge.jsonl이어야 합니다.
- 데이터셋은 SageMaker 훈련 작업에서 액세스할 수 있는 S3 위치에 업로드해야 합니다.

- 파일은 mm_llm_judge 데이터세트에 필요한 스키마 형식을 따라야 합니다.
- 입력 데이터세트에서는 이미지 속성을 제외하고 모든 레코드가 12k 컨텍스트 길이 미만인 되도록 보장해야 합니다.

스키마 형식 - .jsonl 파일의 각 줄은 다음 필드가 있는 JSON 객체여야 합니다.

- 필수 필드:

prompt: 생성된 응답에 대한 프롬프트가 포함된 문자열입니다.

images: 데이터 속성(Base64로 인코딩된 이미지 문자열)이 있는 객체 목록을 포함하는 배열.

response_A: 기준 응답을 포함하는 문자열입니다.

response_B: 기준 응답과 비교할 대체 응답을 포함하는 문자열입니다.

입력 예

가독성을 위해 다음 예제에는 새 줄과 들여쓰기가 포함되지만 실제 데이터세트에서는 각 레코드가 한 줄에 있어야 합니다.

```
{
  "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 aminal and the second has one animal"
}

```

사용자 지정 데이터셋을 사용하려면 다음 필수 필드를 포함하도록 평가 레시피를 수정합니다. 콘텐츠는 변경하지 마세요.

```

evaluation:
  task: mm_llm_judge
  strategy: judge
  metric: all

```

제한 사항

- 평가당 하나의 .jsonl 파일만 허용됩니다.
- 파일은 정의된 스키마를 엄격하게 따라야 합니다.
- Nova MM Judge 모델은 이미지 참조만 지원합니다.
- Nova MM Judge 모델은 Amazon Nova Micro, Amazon Nova Lite 및 Amazon Nova Pro 사양에서 동일합니다.
- (현재 사용자 지정 구분 기호는 지원되지 않습니다.)
- Amazon S3 이미지 URI는 지원되지 않습니다.
- 입력 데이터셋에서는 이미지 속성을 제외하고 모든 레코드가 12k 컨텍스트 길이 미만인 되도록 보장해야 합니다.

지속적인 사전 훈련(CPT) 체크포인트 평가

지속적인 사전 훈련(CPT) 모델에 대한 평가는 CPT 모델이 정기적으로 지침을 따를 수 없기 때문에 지도 미세 조정(SFT)을 거친 모델보다 더 까다로울 수 있습니다. CPT 모델은 지침을 따르는 대신 완성 모델로 작동합니다. 즉, 입력 토큰 시퀀스와 함께 제공된 패턴만 계속하려고 시도합니다. 이러한 제한 사항을 고려할 때 일반적인 평가 데이터셋은 입력의 'Q&A' 형식으로 인해 제대로 작동하지 않을 수 있습니다. 질문에 답변하는 대신 모델은 동일한 질문으로 계속 진행하려고 시도합니다. 그러나 완료 스타일에서 모델을 프롬프트하는 특정 방식으로 데이터셋 형식을 지정하면 모델의 성능을 이해할 수 있습니다.

아래 단계에 따라 Nova Forge 평가 워크플로를 사용하여 사전 훈련된 지속적 모델에 대한 평가를 수행하는 방법을 이해합니다.

데이터세트 준비 및 형식 지정

CPT 모델 평가는 Nova Forge 모델 평가 경험에 이미 제공된 기존의 [자체 데이터세트 가져오기](#) 워크플로를 활용합니다. 그러나 CPT 모델은 SFT 모델과 동일한 방식으로 표준 질문 스타일 프롬프트에 응답하지 않으므로 데이터세트 내 쿼리는 순수 'completion' 형식으로 지정되어야 합니다.

CPT만 진행하는 모델의 또 다른 중요한 빈번한 제한 사항은 STOP 또는 시퀀스 종료 토큰을 생성할 수 없다는 점입니다. 즉, 모델이 강제로 중지될 때까지 토큰을 계속 생성합니다(예: max_new_tokens 파라미터 사용). 이러한 제한 사항을 고려할 때 모범 사례는 단일 토큰 응답(예: 다중 선택)을 사용하여 모델을 평가함으로써 모델이 프롬프트 후 필요하지 않은 정크 출력을 계속 생성하지 않도록 하는 것입니다.

예를 들어 일반적인 평가 데이터세트(예: MMLU, GPQA, MATH 등)는 다음과 같은 질문으로 모델에 프롬프트를 표시할 수 있습니다.

```
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.)
```

그러나 CPT 모델은 지침 준수에서 미세 조정이 결여되었기 때문에 이 질문에 올바르게 응답하는 방법을 이해하지 못합니다. 따라서 CPT 모델은 다음과 같은 완료 스타일로 프롬프트되어야 합니다.

```
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.)
```

추론을 검사한 후 모델에서 생성된 logprobs 출력은 모델이 입력을 올바르게 처리하고 올바른 응답을 생성했는지에 대한 세부 정보를 제공합니다. 모델이 항상 예상되는 정확한 응답(이 경우 문자 D)을 생성한다는 보장은 없지만 모델이 올바르게 작동하는 경우 해당 응답이 logprobs 내에 있어야 합니다.

다중 선택이 아닌 또 다른 완료 스타일 프롬프트 예제:

The capital of France is

(Expected answer of Paris)

모델은 'Paris'의 응답을 생성하거나 logprobs 출력의 어딘가에 'Paris'에 해당하는 토큰이 나타날 것으로 예상됩니다.

데이터세트 형식 지정

CPT 평가는 기존의 [자체 데이터세트 가져오기](#) 워크플로를 활용합니다. 데이터는 JSONL 파일에서 새 줄로 구분된 'query response' 형식으로 지정되어야 합니다.

4개의 항목이 포함된 데이터세트 예제:

```
{ "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" }
```

각 줄에는 다음이 포함되어야 합니다.

- query: 완료를 위한 프롬프트 텍스트
- response: 예상 완료(실측 정보)

모델은 채팅 형식을 지정하지 않고 원시 텍스트 입력을 수신합니다. CPT 모델은 일반적으로 아직 특수 토큰에서 훈련되지 않았으며 채팅 템플릿에 제대로 응답하지 않으므로 모델에 프롬프트를 표시할 때 쿼리에 제공된 문자열만 모델로 전송됩니다(이때 추가 [BOS] 토큰이 자동으로 앞에 추가됨).

레시피 구성

다음은 CPT 모델을 평가하도록 구성된 레시피에 대한 예제입니다.

```
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
```

CPT 평가에 대한 주요 변경 내용:

- `checkpoint_is_instruction_tuned: "false"`

이는 CPT 체크포인트에서 평가 실행을 지원하기 위해 특별히 추가된 새 파라미터입니다.

`checkpoint_is_instruction_tuned`를 `false`로 설정하면 일반적으로 입력 프롬프트를 래핑하는 기본 Amazon Nova 채팅 템플릿이 비활성화됩니다.

- `top_logprobs: 5`

로그 확률(logprobs)은 잠재적 다음 토큰에서 모델의 신뢰도 분포를 보여주므로 모델이 사전 훈련 중에 예상 완료를 학습했는지를 평가하는 데 도움이 됩니다. 일반적으로 모델이 의도한 대로 실행되는 경우 예상 응답(예: 'A', 'B' 등)이 생성된 출력 토큰 또는 logprobs의 토큰으로 나타날 수 있습니다.

- `max_new_tokens: 1`

CPT 모델은 일반적으로 추론을 중지할 시점을 알리기 위해 아직 특별한 'stop' 또는 'end of sequence' 토큰을 생성하는 방법에 대해 훈련되지 않았습니다. 즉, 모델은 일반적으로 특정 최대 토큰 길이에 도달할 때까지 새 토큰을 계속 생성하여 불필요한 추론을 초래합니다. 일반적으로 `max_new_tokens`를 1로 제한하고 단일 응답으로 모델을 평가할 수 있는 프롬프트(예: 다중 선택 질문)를 제공하는 것이 모델을 프롬프트하는 가장 효율적인 방법입니다. `max_new_tokens`를 1로 설정하면 추가 정크 토큰이 생성되지 않습니다.

키 파라미터

- `checkpoint_is_instruction_tuned`: 채팅 템플릿을 비활성화하려면 `"false"`(또는 부울 형식의 `false`)로 설정해야 함
- `top_logprobs`: 5, CPT 중에 모델이 학습하는 방식을 확인하는 데 권장됨
- `task`: `gen_qa`여야 함 - CPT 모델은 MMLU 또는 MATH와 같은 지침 준수 벤치마크를 사용할 수 없음
- `strategy`: `gen_qa`여야 함
- `max_new_tokens`: CPT 모델이 생성이 아닌 완료를 수행하기 때문에 낮은 수준(1~5)을 유지하도록 권장

평가 훈련 작업 실행

다음 샘플 노트북을 사용하여 훈련 작업을 시작합니다. 평가 훈련 작업을 실행하려면 아래 노트북을 예제로 참조하세요. 자세한 내용은 [SageMaker AI 예측기를 사용하여 훈련 작업 실행](#)을 참조하세요.

참조 테이블

노트북을 실행하기 전에 다음 참조 테이블을 참조하여 이미지 URI 및 인스턴스 구성을 선택합니다.

이미지 URI 선택

방법	이미지 URI
평가 이미지 URI	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-TJ-Eval-V2-latest

인스턴스 유형 및 개수 선택

모델	작업 유형	인스턴스 유형	권장 인스턴스 수	허용된 인스턴스 수
Amazon Nova Micro	평가(SFT/DPO)	g5.12xlarge	1	1~16
Amazon Nova Lite	평가(SFT/DPO)	g5.12xlarge	1	1~16
Amazon Nova Pro	평가(SFT/DPO)	p5.48xlarge	1	1~16

샘플 노트북

다음 샘플 노트북은 평가 훈련 작업을 실행하는 방법을 보여줍니다.

```
# 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})

```

평가 결과 평가 및 분석

평가 작업이 성공적으로 완료되면 다음 단계를 사용하여 결과를 평가하고 분석할 수 있습니다.

결과를 평가하고 분석하려면 다음 단계를 따릅니다.

1. 출력 위치 구조를 이해합니다. 결과는 지정된 Amazon S3 출력 위치에 압축 파일로 저장됩니다.

```

s3://your-bucket/output/benchmark-name/
### job_name/
    ### output/
        ### output.tar.gz

```

2. 버킷에서 output.tar.gz 파일을 다운로드합니다. 콘텐츠를 추출하여 공개합니다.

```

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 - 출력 지표 JSON 파일
- details_<task_name>_#_<datetime>.parquet - 추론 출력 파일(strong_reject 제외)
- events.out.tfevents.[timestamp] - TensorBoard 출력 파일
- inference_output.jsonl - 정리된 추론 출력 파일(gen_qa 태스크만 해당)

3. TensorBoard에서 결과를 봅니다. 평가 지표를 시각화하려면:

1. S3 버킷에 추출된 폴더 업로드합니다.
 2. SageMaker AI Tensorboard로 이동
 3. 'S3 폴더'를 선택합니다.
 4. S3 폴더 경로를 추가합니다.
 5. 동기화가 완료될 때까지 기다립니다.
4. 추론 출력을 분석합니다. `llm_judge` 및 `strong_reject`를 제외한 모든 평가 태스크의 추론 출력에는 분석을 위한 다음 필드가 있습니다.
- `full_prompt` - 평가 태스크에 사용되는 모델로 전송되는 전체 사용자 프롬프트.
 - `gold` - 데이터세트에 지정된 정답이 포함된 필드.
 - `metrics` - 개별 추론에 대해 평가된 지표가 포함된 필드. 집계기 필요한 값은 개별 추론 출력에 값을 갖지 않습니다.
 - `predictions` - 지정된 프롬프트에 대한 모델 출력 목록이 포함된 필드.
 - `pred_logits` - 메시지 콘텐츠에서 반환된 각 출력 토큰의 고려된 출력 토큰 수와 로그 확률을 포함하는 필드.

이러한 필드를 보면 지표 차이의 원인을 파악하고 사용자 지정 모델의 동작을 이해할 수 있습니다.

`llm_judge`의 경우 추론 출력 파일의 지표 필드에는 각 평가 쌍별로 다음 필드가 포함됩니다.

- `forward_output` - 정순으로 평가할 때 판단자의 원시 선호도(`response_A`, `response_B`).
- `backward_output` - 역순으로 평가할 때 판단자의 원시 선호도(`response_B`, `response_A`).
- `Pairwise metrics` - 순방향 및 역방향 평가 쌍별로 계산되는 지표로, 여기에는 `a_scores`, `b_scores`, `ties`, `inference-score` 및 `score` 등이 포함됩니다.

Note

`winrate`와 같은 집계 지표는 개별 판단이 아닌 요약 결과 파일에서만 사용할 수 있습니다.

`gen_qa`의 경우 `inference_output.jsonl` 파일에는 각 JSON 객체에 대해 다음 필드가 포함됩니다.

- `prompt` - 모델에 제출된 최종 프롬프트

- inference - 모델의 원시 추론 출력
- gold - 입력 데이터세트의 대상 응답
- metadata - 제공된 경우 입력 데이터세트의 메타데이터 문자열

평가 모범 사례 및 문제 해결

모범 사례

다음 목록은 평가 프로세스의 몇 가지 모범 사례입니다.

- 출력 경로를 모델 및 벤치마크 유형별로 정리하여 유지합니다.
- 쉽게 추적할 수 있도록 일관된 이름 지정 규칙을 유지합니다.
- 추출된 결과를 안전한 위치에 저장합니다.
- TensorBoard 동기화 상태를 모니터링하여 데이터가 성공적으로 로드되었는지 확인합니다.

문제 해결

CloudWatch 로그 그룹 `/aws/sagemaker/TrainingJobs`를 훈련 작업 오류 로그에 사용할 수 있습니다.

엔진 코어 장애

문제:

다음이나 나타나는 경우:

```
RuntimeError: Engine core initialization failed.
```

원인:

여러 원인이 있을 수 있는 일반적인 오류이지만 일반적으로 로드하려는 모델 체크포인트와 지정된 모델 유형이 일치하지 않을 때 나타납니다. 예를 들어 미세 조정된 Nova 2.0 Lite 모델 체크포인트를 평가하려고 하지만 제공하는 모델 유형은 1.0 모델 유형입니다(예: `amazon.nova-micro-v1:0:128k`).

올바른 매핑은 다음과 같아야 합니다.

```
model_type: amazon.nova-2-lite-v1:0:256k
model_name_or_path: nova-lite-2/prod # or s3://escrow_bucket/model_location
```

예방책:

평가 작업을 제출하기 전에 `model_name_or_path`가 오른쪽 `model_type`에 매핑되었는지 다시 확인합니다.

사용 가능한 하위 태스크

다음은 대규모 멀티 태스크 언어 이해(MMLU), Big Bench Hard(BBH), MATH 및 대규모 다분야 멀티모달 이해(MMMU)를 포함한 여러 도메인에서 모델 평가에 사용할 수 있는 하위 태스크의 목록입니다. 이러한 하위 태스크를 통해 모델의 특정 기능 및 지식 영역에서 성능을 평가할 수 있습니다.

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"
]

```

수학 연산

```

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",
```

다양한 평가 방법 및 지표를 사용하여 사용자 지정된 Nova 모델을 평가합니다.

이 섹션의 내용:

- [추론 모델 평가](#)
- [RFT 평가](#)
- [보상 함수 구현](#)

추론 모델 평가

개요

추론 모델 지원을 사용하면 최종 응답을 생성하기 전에 명시적인 내부 추론을 수행하는 추론 가능 Nova 모델을 사용하여 평가할 수 있습니다. 이 기능은 `reasoning_effort` 파라미터를 통한 API 수준 제어를 사용하여 추론 기능을 동적으로 활성화하거나 비활성화함으로써 복잡한 분석 태스크에 대한 응답 품질을 개선할 수 있습니다.

지원되는 모델

- amazon.nova-2-lite-v1:0:256k

레시피 구성

레시피의 `inference` 섹션에 `reasoning_effort` 파라미터를 추가하여 추론을 활성화합니다.

```
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)
```

reasoning_effort 파라미터 사용

`reasoning_effort` 파라미터는 추론 가능 모델의 추론 동작을 제어합니다.

사전 조건

- 모델 호환성 - `model_type`이 추론 가능 모델(현재 `amazon.nova-2-lite-v1:0:256k`)을 지정하는 경우에만 `reasoning_effort`를 설정함
- 오류 처리 - 지원되지 않는 모델과 함께 `reasoning_effort`를 사용하면 `ConfigValidationError: "Reasoning mode is enabled but model '{model_type}' does not support reasoning. Please use a reasoning-capable model or disable reasoning mode."`에서 실패함

사용 가능한 옵션

옵션	동작	토큰 제한	사용 사례:
<code>null</code> (기본값)	추론 모드 비활성화	해당 사항 없음	추론 오버헤드가 없는 표준 평가
<code>low</code>	제약 조건과의 추론 활성화	내부 추론을 위한 4,000개의 토큰	간결한 추론이 필요한 시나리오, 속도와 비용에 맞게 최적화
높음	제약 조건 없이 추론 활성화	내부 추론에 대한 토큰 제한 없음	광범위한 분석 및 단계별 추론이 필요한 복잡한 문제

훈련 방법	사용 가능한 옵션	구성 방법
지도 미세 조정(SFT)	높음 또는 꺼짐만	<code>reasoning_enabled: true(high)</code> 또는 <code>reasoning_enabled: false(off)</code> 사용
강화 미세 조정(RFT)	낮음, 높음 또는 꺼짐	<code>reasoning_effort: low</code> 또는 <code>reasoning_effort: high</code> 를 사용합니다. 비활성화하려면 필드를 생략합니다.
평가	낮음, 높음 또는 꺼짐	<code>reasoning_effort: low</code> 또는 <code>reasoning_effort: high</code> 를 사용합니다. 비활성화하려면 <code>null</code> 을 사용합니다.

추론을 활성화하는 경우

추론 모드(**low** 또는 **high**)를 사용하는 경우

- 복잡한 문제 해결 태스크(수학, 논리적 퍼즐, 코딩)
- 중간 추론이 필요한 다단계 분석 질문
- 자세한 설명 또는 단계별 사고로 정확도가 향상되는 태스크
- 응답 품질이 속도보다 우선되는 시나리오

비추론 모드(**null** 또는 파라미터 생략)를 사용하는 경우

- 간단한 Q&A 또는 실제 쿼리
- 창의적 쓰기 태스크
- 더 빠른 응답 시간이 중요한 경우
- 추론 오버헤드를 제외해야 하는 성능 벤치마킹
- 추론으로 태스크 성능이 개선되지 않는 경우 비용 최적화

문제 해결

오류: 'Reasoning mode is enabled but model does not support reasoning'

원인: `reasoning_effort` 파라미터가 `null`이 아닌 값으로 설정되었지만 지정된 `model_type`에서 추론을 지원하지 않습니다.

해결 방법:

- 모델 유형이 `amazon.nova-2-lite-v1:0:256k`인지 확인
- 다른 모델을 사용하는 경우 추론 가능 모델로 전환하거나 레시피에서 `reasoning_effort` 파라미터를 제거합니다.

RFT 평가

RFT 평가란 무엇인가요?

RFT 평가를 사용하면 강화 학습 훈련 이전, 도중 또는 이후에 사용자 지정 보상 함수를 통해 모델의 성능을 평가할 수 있습니다. 사전 정의된 지표를 사용하는 표준 평가와 달리, RFT 평가를 사용하면 특정

요구 사항에 따라 모델 출력의 점수를 계산하는 Lambda 함수를 통해 고유한 성공 기준을 정의할 수 있습니다.

RFT로 평가하는 이유는 무엇인가요?

RL 미세 조정 프로세스에서 다음을 지원하는지 확인하려면 평가가 중요합니다.

- 특정 사용 사례 및 인적 값에 맞게 모델 정렬 개선
- 주요 태스크에 대한 모델 기능 유지 관리 또는 개선
- 다른 태스크에서 사실성 감소, 세부성 증가 또는 성능 저하와 같은 의도하지 않은 부작용 방지
- 보상 함수에 정의된 대로 사용자 지정 성공 기준 충족

RFT 평가를 사용해야 하는 경우

다음 시나리오에서 RFT 평가를 사용합니다.

- RFT 훈련 이전: 평가 데이터세트에서 기준 지표 설정
- RFT 훈련 도중: 중간 체크포인트를 사용하여 훈련 진행 상황 모니터링
- RFT 훈련 이후: 최종 모델이 요구 사항을 충족하는지 검증
- 모델 비교: 일관된 보상 기준을 사용하여 여러 모델 버전 평가

Note

사용자 지정 도메인별 지표가 필요한 경우 RFT 평가를 사용합니다. 범용 평가(정확성, 복잡성, BLEU)의 경우 표준 평가 방법을 사용합니다.

데이터 형식 요구 사항

입력 데이터 구조

RFT 평가 입력 데이터는 OpenAI 강화 미세 조정 형식을 따라야 합니다. 각 예제는 다음을 포함하는 JSON 객체입니다.

- `messages` - `system` 및 `user` 역할을 포함하는 대화 턴 배열
- `reference_answer` - 보상 함수가 점수 계산을 위해 사용하는 예상 출력 또는 실측 데이터

데이터 형식 예제

```
{
  "messages": [
    {
      "role": "user",
      "content": [
        {
          "type": "text",
          "text": "Solve for x. Return only JSON like {\"x\": <number>}. Equation: 2x + 5 = 13"
        }
      ]
    }
  ],
  "reference_answer": {
    "x": 4
  }
}
```

현재 제한 사항

- 텍스트만 해당: 멀티모달 입력(이미지, 오디오, 비디오)은 지원되지 않음
- 싱글턴 대화: 단일 사용자 메시지만 지원(멀티턴 대화 없음)
- JSON 형식: 입력 데이터는 JSONL 형식이어야 함(줄당 JSON 객체 1개)
- 모델 출력: 지정된 모델에서 생성된 완료를 대상으로 평가가 수행됨

평가 레시피 준비

샘플 노트북

전체 예제는 [평가 노트북](#)을 참조하세요.

샘플 레시피 구성

```
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>

```

보상 함수 사전 설정

RFT Lambda 함수에 쉽게 통합할 수 있도록 두 가지 사전 설정 보상 함수(prime_code 및 prime_math)를 Lambda 계층으로 사용할 수 있습니다.

개요

이러한 사전 설정 함수는 다음에 대한 즉각적인 평가 기능을 제공합니다.

- prime_code - 코드 생성 및 정확성 평가
- prime_math - 수학적 추론 및 문제 해결 평가

빠른 설정

1. [nova-custom-eval-sdk 릴리스](#)에서 Lambda 계층을 다운로드하세요.
2. AWS Command Line Interface(AWS CLI)를 사용하여 Lambda 계층을 게시하세요.

```
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. AWS Management Console에서 Lambda 함수에 계층을 추가하세요(사용자 지정 계층에서 preset-function-layer를 선택하고 numpy 종속성에서 AWSSDKPandas-Python312도 추가).
4. Lambda 코드에서 다음을 가져와 사용하세요.

```
from prime_code import compute_score # For code evaluation
from prime_math import compute_score # For math evaluation
```

prime_code 함수

테스트 사례를 기준으로 코드를 실행하고 정확성을 측정하여 Python 코드 생성 작업을 평가합니다.

입력 데이터세트 형식 예제

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

주요 기능

- 마크다운 코드 블록에서 자동 코드 추출
- 함수 탐지 및 직접 호출 기반 테스트
- 제한 시간 보호를 사용하는 테스트 사례 실행
- 구문 검증 및 컴파일 검사
- 트레이스백을 사용하는 세부 오류 보고

prime_math 함수

기호 수학 지원을 통해 수학 추론 및 문제 해결 기능을 평가합니다.

입력 형식

```
{"messages":[{"role":"user","content":"What is the derivative of  $x^2 + 3x$ ?."}], "reference_answer":" $2x + 3$ "}
```

주요 기능

- SymPy를 사용하는 기호 수학 평가
- 여러 응답 형식(LaTeX, 일반 텍스트, 기호)
- 수학적 동등성 검사
- 표현식 정규화 및 단순화

데이터 형식 요구 사항

코드 평가의 경우

- 입력: 함수 인수의 배열(적절한 유형: 정수, 문자열 등)
- 출력: 예상 반환 값의 배열(적절한 유형: 부울, 숫자 등)
- 코드: 명확한 함수 정의를 포함하는 Python에 있어야 함

수학 평가의 경우

- 참조 답변: 수학 표현식 또는 숫자 값
- 응답: LaTeX, 일반 텍스트 또는 기호 표기법일 수 있음
- 동등성: 문자열 일치뿐만 아니라 기호적으로 확인됨

모범 사례

- 테스트 사례에서 적절한 데이터 유형 사용(정수 대 문자열, 부울 대 'True')
- 코드 문제에서 명확한 함수 서명 제공
- 테스트 입력에서 엣지 케이스 포함(0, 음수, 빈 입력)
- 참조 답변에서 일관된 수학 표현식 형식 지정
- 배포 전에 샘플 데이터를 사용하여 보상 함수 테스트

오류 처리

두 함수 모두 다음에 대한 강력한 오류 처리 기능을 포함합니다.

- 생성된 코드에서 컴파일 오류
- 실행 중 런타임 예외
- 잘못 구성된 입력 데이터
- 무한 루프에 대한 제한 시간 시나리오
- 유효하지 않은 수학 표현식

보상 함수 생성

Lambda ARN 요구 사항

Lambda ARN은 다음 형식을 따라야 합니다.

```
"arn:aws:lambda:*:*:function:*SageMaker"
```

Lambda에 이 이름 지정 스키마가 없는 경우 이 오류가 발생하며 작업이 실패합니다.

```
[ERROR] Unexpected error: lambda_arn must contain one of: ['SageMaker', 'sagemaker', 'Sagemaker'] when running on SMHP platform (Key: lambda_arn)
```

Lambda 요청 형식

Lambda 함수는 다음 형식으로 데이터를 수신합니다.

```
[
  {
    "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

메시지 구조에는 입력 데이터 형식과 일치하는 중첩된 content 배열이 포함됩니다. nova_assistant 역할이 있는 마지막 메시지에는 모델의 생성된 응답이 포함됩니다.

Lambda 응답 형식

Lambda 함수는 다음 형식으로 데이터를 반환해야 합니다.

```

[
  {
    "id": "sample-001",
    "aggregate_reward_score": 0.75,
    "metrics_list": [
      {
        "name": "accuracy",
        "value": 0.85,
        "type": "Metric"
      },
      {
        "name": "fluency",

```

```

        "value": 0.90,
        "type": "Reward"
    }
]
}
]
```

응답 필드

- `id` - 입력 샘플 ID와 일치해야 함
- `aggregate_reward_score` - 전체 점수(일반적으로 0.0~1.0)
- `metrics_list` - 다음을 포함하는 개별 지표의 배열:
 - `name` - 지표 식별자(예: 'accuracy', 'fluency')
 - `value` - 지표 점수(일반적으로 0.0~1.0)
 - `type` - 'Metric'(보고용) 또는 'Reward'(훈련에 사용됨)

IAM 권한

필수 권한

SageMaker 실행 역할에는 Lambda 함수를 간접 호출할 권한이 있어야 합니다. SageMaker 실행 역할에 이 정책을 추가합니다.

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "lambda:InvokeFunction"
      ],
      "Resource": "arn:aws:lambda:region:account-id:function:function-name"
    }
  ]
}
```

Lambda 실행 역할

Lambda 함수의 실행 역할에는 기본 Lambda 실행 권한이 필요합니다.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "logs:CreateLogGroup",
        "logs:CreateLogStream",
        "logs:PutLogEvents"
      ],
      "Resource": "arn:aws:logs:*:*:*"
    }
  ]
}
```

Lambda 함수가 다른 AWS 서비스(예: 참조 데이터의 경우 S3, 로깅의 경우 DynamoDB)에 액세스하는 경우 해당 권한을 Lambda 실행 역할에 추가합니다.

평가 작업 실행

1. 데이터 준비 - 데이터 형식 요구 사항에 따라 평가 데이터의 형식을 지정하고 S3에 JSONL 파일 업로드: `s3://your-bucket/eval-data/eval_data.jsonl`
2. 레시피 구성 - 사용자 구성으로 샘플 레시피 업데이트:
 - `model_name_or_path`를 모델 위치로 설정
 - `lambda_arn`을 보상 함수 ARN으로 설정
 - `output_s3_path`를 원하는 출력 위치로 설정
 - 필요에 따라 `inference` 파라미터 조정

레시피를 `rft_eval_recipe.yaml`로 저장

3. 평가 실행 - 제공된 노트북: 평가 노트북을 사용하여 평가 작업 실행: [평가 노트북](#)
4. 진행 상황 모니터링 - 다음을 통해 평가 작업을 모니터링합니다.
 - SageMaker 콘솔: 작업 상태 및 로그 확인
 - CloudWatch Logs: 세부 실행 로그 보기
 - Lambda 로그: 보상 함수 문제 디버깅

평가 결과 이해

출력 형식

평가 작업은 결과를 지정된 S3 위치에 JSONL 형식으로 출력합니다. 각 줄에는 하나의 샘플에 대한 평가 결과가 포함됩니다.

```
{
  "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

RFT 평가 작업 출력은 Lambda 응답 형식과 동일합니다. 평가 서비스는 Lambda 함수의 응답을 수정하지 않고 전달하여 보상 계산과 최종 결과 사이의 일관성을 보장합니다.

결과 해석

보상 점수 집계

- 범위: 일반적으로 0.0(최저)~1.0(최상)이지만 구현에 따라 다름
- 용도: 전체 성능을 요약하는 단일 숫자
- 사용법: 모델 비교, 훈련 대비 개선 추적

개별 지표

- 지표 유형: 분석을 위한 정보용 지표

- 보상 유형: RFT 훈련 도중 사용되는 지표
- 해석: 반대 지표를 설계하지 않는 한, 값이 높을수록 일반적으로 더 나은 성능을 나타냄

성능 벤치마크

'양호'한 성능을 구성하는 요소는 사용 사례에 따라 달라집니다.

점수 범위	해석	작업
0.8 - 1.0	우수	배포 준비된 모델
0.6~0.8	양호	약간의 개선이 도움이 될 수 있음
0.4~0.6	공정	상당한 개선이 필요함
0.0~0.4	열악	훈련 데이터 및 보상 함수 검토

Important

다음은 일반적인 지침입니다. 비즈니스 요구 사항, 기준 모델 성능, 도메인별 제약 조건 및 추가 훈련의 비용 편익 분석을 기반으로 자체 임계치를 정의합니다.

문제 해결

일반적인 문제

문제	원인	솔루션
Lambda 제한 시간	복잡한 보상 계산	Lambda 제한 시간 증가 또는 함수 최적화
권한 거부됨	IAM 권한 누락	SageMaker 역할이 Lambda를 간접 호출할 수 있는지 확인
일관되지 않은 점수	비결정적 보상 함수	고정 시드 또는 결정론적 로직 사용

문제	원인	솔루션
누락된 결과	Lambda 오류가 발견되지 않음	Lambda에서 포괄적인 오류 처리 추가

디버그 체크리스트

- 입력 데이터가 중첩된 콘텐츠 배열을 사용하여 올바른 형식을 따르는지 확인
- Lambda ARN이 올바르고 함수가 배포되었는지 확인
- SageMaker → Lambda 간접 호출에 대한 IAM 권한 확인
- CloudWatch 로그에서 Lambda 오류 검토
- Lambda 응답이 예상 형식과 일치하는지 확인

모범 사례

- 간단하게 시작: 기본 보상 함수로 시작하고 반복
- 별도로 Lambda 테스트: 전체 평가 전에 Lambda 테스트 이벤트 사용
- 소규모 데이터세트에서 검증: 전체 데이터세트 이전에 하위 세트에서 평가 실행
- 버전 제어: 모델 버전과 함께 보상 함수 버전 추적
- 비용 모니터링: Lambda 간접 호출 및 컴퓨팅 시간이 비용에 미치는 영향
- 포괄적인 로그: 디버깅을 위해 Lambda에서 print 문 사용
- 적절한 제한 시간 설정: 인내와 비용 사이의 균형
- 지표 문서화: 각 지표가 측정하는 항목을 명확하게 정의

다음 단계

RFT 평가를 완료한 후:

- 결과가 만족스러운 경우: 프로덕션에 모델 배포
- 개선이 필요한 경우:
 - 보상 함수 조정
 - 더 많은 훈련 데이터 수집
 - 훈련 하이퍼파라미터 수정

- 추가 RFT 훈련 반복 실행
- 지속적인 모니터링: 새 데이터를 사용하여 주기적으로 재평가

보상 함수 구현

개요

보상 함수(점수 계산기 또는 등급 계산기라고도 함)는 모델 응답을 평가하고 훈련을 위한 피드백 신호를 제공하는 핵심 구성 요소입니다. 이는 모델 응답을 수락하고 보상 점수를 반환하는 Lambda 함수로 구현해야 합니다.

인터페이스 형식

보상 함수는 다음 형식으로 데이터를 수락하고 반환해야 합니다.

훈련을 위한 샘플 입력 샘플

```
{
  "messages": [
    {
      "role": "user",
      "content": "Do you have a dedicated security team?"
    }
  ],
  "reference_answer": {
    "compliant": "No",
    "explanation": "As an AI developed by Company, I do not have a traditional security team..."
  }
}
```

보상 Lambda용 샘플 페이로드

컨테이너는 다음을 통해 데이터를 Lambda 함수로 전송하기 전에 데이터를 자동으로 변환합니다.

1. 각 프롬프트에 대한 모델 응답 생성
2. 메시지 배열에 어시스턴트 턴(생성된 응답) 추가
3. 추적을 위한 고유한 id 필드 추가

Lambda 함수는 이러한 변환된 형식으로 데이터를 수신합니다.

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

보상 Lambda 계약

```
def lambda_handler(event, context):
    return lambda_grader(event)

def lambda_grader(samples: list[dict]) -> list[dict]:
    """
    Args:
        samples: List of dictionaries in OpenAI format

    Example input:
    {
        "id": "123",
        "messages": [
            {
                "role": "user",
                "content": "Do you have a dedicated security team?"
            },
            {
                "role": "assistant",
                "content": "As an AI developed by Company, I don nott have a
dedicated security team..."
            }
        ]
    }
```

```

    }
    ],
    # This section will be same as your training dataset
    "reference_answer": {
        "compliant": "No",
        "explanation": "As an AI developed by Company, I do not have a
traditional security team..."
    }
}

Returns:
List of dictionaries with reward scores:
{
    "id": str,                                # Same id as input sample
    "aggregate_reward_score": float,          # Overall score for the sample
    "metrics_list": [                         # OPTIONAL: Component scores
        {
            "name": str,                      # Name of the component score
            "value": float,                   # Value of the component score
            "type": str                       # "Reward" or "Metric"
        }
    ]
}
"""

```

입력 및 출력 필드

입력 필드

필드	설명	추가 참고 사항
id	샘플의 고유 식별자	출력에서 다시 반환됩니다. 문자열 형식
messages	정렬된 채팅 기록(OpenAI 형식)	메시지 객체 배열
messages[].role	메시지의 화자	일반적인 값: "user", "assistant", "system"
messages[].content	메시지의 텍스트 콘텐츠	일반 문자열

필드	설명	추가 참고 사항
**metadata	등급 지정에 도움이 되는 자유 양식 정보	객체, 훈련 데이터에서 전달되는 선택적 필드

출력 필드

필드	설명	추가 참고 사항
id	입력 샘플과 동일한 식별자	입력과 일치해야 함
aggregate_reward_score	샘플의 전체 점수	부동 소수점(예: 0.0~1.0 또는 태스크 정의 범위)
metrics_list	집계를 구성하는 구성 요소 점수	지표 객체의 배열

기술적 제약 조건

- 제한 시간 - Lambda 간접 호출당 최대 15분의 실행 시간
- 동시성 - rollout_worker_replicas * 64 동시 요청을 처리해야 함
- 신뢰성 - 적절한 오류 처리를 구현하고 유효한 점수를 일관되게 반환해야 함
- 성능 - 빠른 실행(분이 아닌 초 단위)을 위해 최적화하여 효율적인 훈련을 지원함

모범 사례

- 외부 API 직접 호출 최소화
- 효율적인 알고리즘 및 데이터 구조 사용
- 일시적인 장애에 대한 재시도 로직 구현
- 캐시 재사용 가능 계산
- 훈련 전에 철저히 테스트하여 버그 없는 실행 보장

사용자 지정 보상 함수 사용

태스크별 평가 기준이 있는 경우 사용자 지정 보상 함수를 구현합니다.

- 평가 기준 정의 - 태스크에 대해 좋은 응답을 만드는 요소 결정
- Lambda 함수 구현 - 인터페이스 형식에 따라 Lambda 함수 생성
- 로컬에서 테스트 - 함수가 샘플 입력에 대해 올바른 점수를 반환하는지 검증
- AWS에 배포 - Lambda를 배포하고 ARN 기록
- 레시피 구성 - Lambda ARN을 레시피의 `reward_lambda_arn` 필드에 추가
- 소규모 데이터셋으로 테스트 - 최소한의 데이터로 RFT를 실행하여 통합 확인

IAM 권한

필수 권한

SageMaker 실행 역할에는 Lambda 함수를 간접 호출할 권한이 있어야 합니다. SageMaker 실행 역할에 이 정책을 추가합니다.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "lambda:InvokeFunction"
      ],
      "Resource": "arn:aws:lambda:region:account-id:function:function-name"
    }
  ]
}
```

Lambda 실행 역할

Lambda 함수의 실행 역할에는 기본 Lambda 실행 권한이 필요합니다.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "logs:CreateLogGroup",
        "logs:CreateLogStream",
        "logs:PutLogEvents"
      ]
    }
  ]
}
```

```
    ],
    "Resource": "arn:aws:logs:*:*:*"
  }
]
}
```

추가 권한: Lambda 함수가 다른 AWS 서비스(예: 참조 데이터의 경우 S3, 로깅의 경우 DynamoDB)에 액세스하는 경우 해당 권한을 Lambda 실행 역할에 추가합니다.

예: 평가형 LLM 보상 함수

이 예제에서는 Amazon Bedrock 모델을 평가자로 사용하여 모델 응답을 참조 답변과 비교하여 평가하는 방법을 보여줍니다. 이 Lambda 템플릿은 고객이 평가자의 평가를 처리하기 위한 추론 요청에 대해 Amazon Bedrock에 대한 직접 호출을 구현할 수 있는 프레임워크를 제공합니다. Lambda 함수는 다른 보상 함수와 동일한 입력/출력 계약을 유지 관리합니다.

구현

이 Lambda 함수는 2단계 평가 프로세스를 구현합니다. 즉, `lambda_handler`는 수신 샘플에서 모델 응답과 참조 응답을 추출한 다음, `lambda_graded` 함수에서 Amazon Bedrock을 직접 호출하여 이들 간의 시맨틱 유사성을 평가합니다. 이 구현에서는 일시적인 장애에 대한 자동 재시도를 통한 강력한 오류 처리를 포함하며 유연한 참조 응답 형식(문자열 및 구조화된 사전 형식 모두)을 지원합니다.

구현 세부 정보:

- 재시도 로직: Bedrock API 사용량 제한을 처리하기 위해 스로틀링 예외에 대한 지수 백오프(1초, 2초, 4초) 구현
- 오류 처리: 예외를 발생시키는 대신, 실패한 평가에 대해 0.0의 점수 반환
- 결정적 점수: 온도=0.0을 사용하여 여러 평가에서 일관된 점수 보장
- 유연한 참조 형식: 문자열 및 사전 참조 답변 모두를 자동으로 처리
- 점수 고정: 모든 점수가 유효한 [0.0, 1.0] 범위 내에 있는지 확인
- 모델 무관: 모든 Amazon Bedrock 모델(Nova, Llama, Mistral 등)을 사용하도록 JUDGE_MODEL_ID 변경

```
"""
LLM Judge Lambda POC - Working implementation using Amazon Bedrock
"""

import json
```

```
import time
import boto3

bedrock_runtime = boto3.client('bedrock-runtime', region_name='us-east-1')
JUDGE_MODEL_ID = "anthropic.claude-3-5-sonnet-20240620-v1:0"
SYSTEM_PROMPT = "You must output ONLY a number between 0.0 and 1.0. No explanations, no text, just the number."

JUDGE_PROMPT_TEMPLATE = """Compare the following two responses and rate how similar they are on a scale of 0.0 to 1.0, where:
- 1.0 means the responses are semantically equivalent (same meaning, even if worded differently)
- 0.5 means the responses are partially similar
- 0.0 means the responses are completely different or contradictory

Response A: {response_a}

Response B: {response_b}

Output ONLY a number between 0.0 and 1.0. No explanations."""

def lambda_graded(response_a: str, response_b: str, max_retries: int = 3) -> float:
    """Call Bedrock to compare responses and return similarity score."""
    prompt = JUDGE_PROMPT_TEMPLATE.format(response_a=response_a, response_b=response_b)

    for attempt in range(max_retries):
        try:
            response = bedrock_runtime.converse(
                modelId=JUDGE_MODEL_ID,
                messages=[{"role": "user", "content": [{"text": prompt}]}],
                system=[{"text": SYSTEM_PROMPT}],
                inferenceConfig={"temperature": 0.0, "maxTokens": 10}
            )
            print(f"Bedrock call successful: {response}")
            output = response['output']['message']['content'][0]['text'].strip()
            score = float(output)
            print(f"Score parsed: {score}")
            return max(0.0, min(1.0, score))

        except Exception as e:
            if "ThrottlingException" in str(e) and attempt < max_retries - 1:
                time.sleep(2 ** attempt)
```

```

        else:
            print(f"Bedrock call failed: {e}")
            return None
    return None

def lambda_handler(event, context):
    """AWS Lambda handler - processes samples from RFTEvalInvoker."""
    try:
        samples = event if isinstance(event, list) else [event]
        results = []

        for sample in samples:
            sample_id = sample.get("id", "unknown")
            messages = sample.get("messages", [])

            # Extract assistant response (response A)
            response_a = ""
            for msg in messages:
                if msg.get("role") in ["assistant", "nova_assistant"]:
                    response_a = msg.get("content", "")
                    break

            # Extract reference answer from root level (no longer in metadata)
            reference_answer = sample.get("reference_answer", "")

            # Handle both string and dict reference_answer formats
            if isinstance(reference_answer, dict):
                # If reference_answer is a dict, extract the explanation or compliant
                field
                response_b = reference_answer.get("explanation",
reference_answer.get("compliant", ""))
            else:
                response_b = reference_answer

            if not response_a or not response_b:
                results.append({
                    "id": sample_id,
                    "aggregate_reward_score": 0.0,
                    "metrics_list": [{"name": "similarity_score", "value": 0.0, "type":
"Metric"}]
                })
                continue

```



```

        # Get similarity score
        score = lambda_graded(response_a, response_b)

        results.append({
            "id": sample_id,
            "aggregate_reward_score": score,
            "metrics_list": [
                {
                    "name": "similarity_score",
                    "value": score,
                    "type": "Metric"
                }
            ]
        })

    return {"statusCode": 200, "body": json.dumps(results)}

except Exception as e:
    print(f"Error: {e}")
    return {"statusCode": 500, "body": json.dumps({"error": str(e)})}

```

입력 형식

Lambda는 다른 보상 함수와 동일한 입력 형식을 수신합니다.

```

{
  "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"
}

```

```
}
```

출력 형식

```
{
  "id": "sample-001",
  "aggregate_reward_score": 0.85,
  "metrics_list": [
    {
      "name": "similarity_score",
      "value": 0.85,
      "type": "Metric"
    }
  ]
}
```

배포 고려 사항

선택한 모델의 기능 및 API 형식에 따라 프롬프트 템플릿 및 추론 파라미터를 조정해야 할 수도 있습니다.

- IAM 권한: Lambda 실행 역할은 선택한 모델에 대한 `bedrock:InvokeModel` 권한을 보유해야 함
- 제한 시간: Bedrock API 지연 시간 및 재시도를 수용할 수 있도록 Lambda 제한 시간을 최소 60초로 설정
- 리전: 선택한 Bedrock 모델이 사용 가능한 리전에 배포
- 비용: 각 평가가 샘플당 하나의 API를 직접 호출할 때 Bedrock API 사용량 모니터링
- 처리량: 대규모 평가의 경우 스로틀링을 방지하기 위해 Bedrock 할당량 증가 요청

Bedrock 처리량 증가

평가 중에 스로틀링이 발생하는 경우 Bedrock 모델 할당량을 늘립니다.

- AWS Service Quotas 콘솔로 이동
- 'Bedrock'을 검색하고 리전 선택
- 선택한 모델의 할당량 찾기(예: 'Claude 3.5 Sonnet에 대한 분당 간접 호출 수')
- '할당량 증가 요청'을 클릭하고 원하는 처리량 지정
- 증가에 대한 근거 제공(예: 'RFT 평가 워크로드')

Lambda의 기본 제공 재시도 로직은 간헐적인 스로틀링을 처리하지만 지속적인 대규모 평가에는 적절한 할당량 증가가 필요합니다.

필수 IAM 정책:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "bedrock:InvokeModel"
      ],
      "Resource": "arn:aws:bedrock:*::foundation-model/*"
    }
  ]
}
```

반복 학습

반복 훈련은 여러 훈련 주기를 통해 모델을 미세 조정하는 체계적인 접근 방식으로, 각 라운드는 평가를 통해 발견된 특정 약점을 해결하여 이전 체크포인트를 기반으로 빌드됩니다. 이 방법을 사용하면 실패 모드를 해결하는 선별된 예제를 통합하고, 변화하는 요구 사항에 적응하며, 긴 단일 훈련 실행에 커밋하는 대신 점진적으로 개선 사항을 검증하여 모델 성능을 목표로 개선할 수 있습니다. 이 프로세스는 일반적으로 지도 미세 조정(SFT) 및 보상 기반 미세 조정(RFT)과 같은 패턴을 따르며, 이때 파이프라인 전체에서 모델 유형 및 훈련 기법의 일관성을 유지 관리하면서 후속 훈련 반복을 위해 참조할 수 있는 AWS 관리형 에스크로 S3 버킷에 체크포인트가 저장됩니다.

자세한 내용은 [??? 단원](#)을 참조하십시오.

SageMaker HyperPod에서 Amazon Nova 사용자 지정

[Amazon Nova 레시피](#)를 사용하여 향상된 Amazon Nova 2.0 모델을 포함한 Amazon Nova 모델을 사용자 지정하고 Hyperpod에서 훈련할 수 있습니다. 레시피는 SageMaker AI가 모델 사용자 지정 작업을 수행하는 방법에 대한 세부 정보를 제공하는 YAML 구성 파일입니다. SageMaker HyperPod는 Forge와 BiForge라는 두 가지 유형의 서비스를 지원합니다.

HyperPod는 최적화된 GPU 인스턴스와 Amazon FSx for Lustre 스토리지를 통한 고속 연산, TensorBoard 등의 도구와의 통합을 통한 강력한 모니터링, 반복적인 성능 향상을 위한 유연한 체크포

인트 관리, Amazon Bedrock으로의 원활한 추론 배포, 효율적이고 확장 가능한 다중 노드 분산 훈련을 통해 고성능 컴퓨팅 환경을 제공합니다. 이 모든 기능이 결합되어 조직이 자신들의 비즈니스 요구 사항에 맞게 Amazon Nova 모델을 안전하고 성능이 뛰어나며 유연성을 갖춘 환경에서 맞춤화할 수 있도록 지원합니다.

SageMaker HyperPod에서 Amazon Nova 모델을 사용자 지정할 경우, 모델 체크포인트를 포함한 모델 아티팩트는 서비스 관리형 Amazon S3 버킷에 저장됩니다. 서비스 관리형 버킷의 아티팩트는 SageMaker AI 관리형 AWS KMS 키로 암호화됩니다. 현재 서비스 관리형 Amazon S3 버킷은 고객 관리형 KMS 키를 사용한 데이터 암호화를 지원하지 않습니다. 이 체크포인트 저장 위치는 평가 작업 또는 Amazon Bedrock 추론에 활용할 수 있습니다.

컴퓨팅 인스턴스, Amazon S3 스토리지 및 FSx for Lustre에 표준 요금이 적용될 수 있습니다. 요금에 대한 자세한 내용은 [Hyperpod 요금](#), [Amazon S3 요금](#), [FSx for Lustre 요금](#)을 참조하세요.

Amazon Nova 2 모델의 컴퓨팅 요구 사항

다음 표에는 Amazon Nova 2 모델에 대한 SageMaker HyperPod 및 SageMaker AI 훈련 작업 훈련의 계산 요구 사항이 요약되어 있습니다.

Nova 2 훈련 요구 사항

훈련 기법	최소 인스턴스	인스턴스 유형	GPU 수	참고	지원되는 모델
SFT(LoRA)	4	P5.48xlarge	16	파라미터 효율적 미세 조정	Nova 2 Lite
SFT(전체 순위)	4	P5.48xlarge	32	전체 모델 미세 조정	Nova 2 Lite
SageMaker 훈련 작업에서 RFT(LoRA)	2	P5.48xlarge	16	AWS 환경에서 사용자 지정 보상 함수	Nova 2 Lite
SageMaker 훈련 작업에서 RFT(전체 순위)	4	P5.48xlarge	32	32K의 컨텍스트 길이	Nova 2 Lite

훈련 기법	최소 인스턴스	인스턴스 유형	GPU 수	참고	지원되는 모델
SageMaker HyperPod에서 RFT	8	P5.48xlarge	64	기본 8,192의 컨텍스트 길이	Nova 2 Lite
CPT	4	P5.48xlarge	16	하루에 인스턴스당 약 400M의 토큰을 처리함	Nova 2 Lite

Hyperpod에서 Amazon Nova 모델 사용자 지정 워크플로를 최적화하려면 효율적인 훈련, 리소스 관리 및 성공적인 모델 배포에 대한 다음과 같은 권장 모범 사례를 따릅니다.

Amazon Nova 사용자 지정 모범 사례

개요

이 섹션에서는 사용자 지정 기법에 대한 개요를 제공하고, 요구 사항과 사용 가능한 데이터에 가장 적합한 접근 방식을 선택하는 데 도움을 줍니다.

LLM 훈련의 두 가지 단계

대규모 언어 모델 훈련은 두 가지 주요 단계(사전 훈련 및 사후 훈련)로 구성됩니다. 사전 훈련 단계에서 모델은 원시 텍스트의 토큰을 처리하고 다음 토큰 예측을 위해 최적화됩니다. 이 프로세스에서는 웹 및 업선된 텍스트에서 구문, 시맨틱, 사실 및 추론 패턴을 흡수하는 패턴 완성기를 생성합니다. 그러나 사전 훈련된 모델은 지침, 사용자 목표 또는 컨텍스트별 동작을 이해하지 못합니다. 훈련 배포에 맞는 스타일로 텍스트를 계속 처리합니다. 사전 훈련된 모델은 지침을 따르는 대신 자동 완성을 수행하고, 일치하지 않는 형식을 생성하며, 훈련 데이터에서 원치 않는 편향이나 안전하지 않은 콘텐츠를 미러링할 수 있습니다. 사전 훈련에서는 태스크 유용성이 아닌 일반적인 기능을 구축합니다.

사후 훈련에서는 패턴 완성기를 유용한 어시스턴트로 변환합니다. 여러 차례의 감독 미세 조정(SFT)을 실행하여 모델이 지침을 따르고, 스키마 및 정책을 준수하며, 도구를 직접 호출하고, 고품질 데모를 모방하여 신뢰할 수 있는 출력을 생성하도록 가르칩니다. 이 조정을 통해 계속 진행하려면 텍스트가 아닌 태스크로 프롬프트에 응답하도록 모델을 가르칩니다. 그런 다음 강화 미세 조정(RFT)을 적용하여 측정 가능한 피드백(예: 확인자 또는 평가형 LLM), 정확도와 간결성, 안전과 적용 범위 또는 제약 조건 아래에서 여러 단계의 추론과 같은 장단점의 균형을 맞춰 동작을 최적화합니다. 실제로 SFT와 RFT를 주기

적으로 교체하여 사전 훈련된 모델을 복잡한 태스크를 일관되게 수행하는 신뢰할 수 있는 정책 조정 시스템으로 구축합니다.

올바른 사용자 지정 접근 방식 선택

이 섹션에서는 사후 훈련 사용자 지정 전략(RFT 및 SFT)을 다룹니다.

강화 미세 조정(RFT)

강화 미세 조정은 정확히 올바른 답변으로 직접 감독하는 대신 응답 품질을 나타내는 피드백 신호(측정 가능한 점수 또는 보상)를 통해 모델 성능을 개선합니다. 입력과 출력 페어로부터 학습하는 기존의 지도 미세 조정과 달리, RFT는 보상 함수를 사용하여 모델 응답을 평가하고 반복적으로 모델을 최적화하여 이러한 보상을 극대화합니다. 이 접근 방식은 정확히 올바른 출력을 정의하기 어려운 태스크에 효과적이지만 신뢰할 수 있는 방식으로 응답 품질을 측정할 수 있습니다. RFT를 사용하면 모델이 시험과 피드백을 통해 복잡한 행동과 선호도를 학습할 수 있으므로, 세심한 의사 결정, 창의적인 문제 해결 또는 프로그래밍 방식으로 평가할 수 있는 특정 품질 기준 준수가 필요한 애플리케이션에 적합합니다. 예를 들어 복잡한 법적 질문에 대한 답변은 RFT의 이상적인 사용 사례입니다. 질문에 더 정확하게 답변하는 방법을 모델에 가르치고 싶기 때문입니다.

작동 방식

강화 미세 조정에서는 지침 조정 기준에서 시작하여 각 프롬프트를 작은 토너먼트와 같이 처리합니다. 주어진 입력에 대해 모델의 몇 가지 후보 답변을 샘플링하고 보상 함수로 각각의 점수를 매긴 후 해당 그룹 내에서 순위를 정합니다. 업데이트 단계에서는 다음에 점수가 내려가지 않고 점수가 더 높아질 수 있도록 모델을 유도하면서, 기존 유지 제약 조건을 통해 동작이 드리프팅되거나 장황해지거나 악용되는 것을 방지합니다. 많은 프롬프트에서 이 루프를 반복하여 하드 케이스를 새로 고치고, 악용이 발견되면 확인자 또는 평가 루브릭을 강화하며, 태스크 지표를 지속적으로 추적합니다.

RFT는 사용하는 경우

RFT를 가장 많이 활용하는 태스크는 몇 가지 특성을 공유합니다. 하나의 올바른 출력을 지정하기 어려운 경우에도 측정 가능한 성공 신호를 제공합니다. 부분 크레딧 또는 등급이 지정된 품질을 인정하므로 프롬프트 내에서 또는 보상 함수를 사용하여 더 좋거나 나쁜 응답의 순위를 정할 수 있습니다. 여기에는 균형을 맞춰야 하는 여러 목표(예: 간결함, 명확함, 안전 또는 비용을 고려한 정확성)가 포함됩니다. 프로그래밍 방식으로 확인할 수 있는 명시적 제약 조건을 준수해야 합니다. 결과를 관찰할 수 있는 도구로 조정되는 설정 또는 환경 기반 설정(성공 또는 실패, 지연 시간, 리소스 사용)에서 작동합니다. 이는 골드 타겟을 수집하는 데 비용이 많이 들지만 자동 피드백이나 루브릭 기반 피드백이 많은 낮은 수준의 레이블 영역에서 나타납니다. RFT는 품질을 신뢰할 수 있는 스칼라 또는 순위로 전환하고 레이블이 지정된 전수 대상 없이도 모델이 더 높은 점수의 동작을 우선적으로 증폭하도록 하는 경우에 가장 효과적입니다.

다음과 같은 경우 다른 방법을 고려합니다.

- 신뢰할 수 있는 많은 레이블이 지정된 입력과 출력 페어가 있는 경우 - SFT 사용
- 기본 격차가 지식 또는 전문 용어에서 발생하는 경우 - 검색 증강 생성(RAG) 사용
- 보상 신호에 노이즈가 있거나 이를 신뢰할 수 없으며 더 나은 루브릭이나 검사기로 수정할 수 없는 경우 - RFT 이전에 먼저 안정화

RFT를 사용하지 말아야 하는 경우

다음과 같은 상황에서는 RFT를 사용하지 않습니다.

- 신뢰할 수 있는 레이블이 지정된 입력과 출력 페어를 저렴하게 생성할 수 있는 경우(SFT가 더 단순하고 저렴하며 안정적임)
- 격차는 동작이 아닌 지식 또는 전문 용어에서 발생하는 경우(RAG 사용)
- 보상 신호에 노이즈가 있거나 희소하거나 쉽게 훈련이 가능하거나 비용이 많이 들거나 컴퓨팅 속도가 느린 경우(먼저 평가자 수정)
- 기존 성능이 0에 가까운 경우(선호도를 최적화하기 전에 SFT로 부트스트랩)
- 태스크에 결정적 스키마, 엄격한 형식 또는 단일 정답이 포함된 경우(SFT 또는 규칙 기반 검증이 더 효과적임)
- 긴 지연 시간 또는 비용 예산인 RFT에 필요한 추가 샘플링 또는 탐색을 수용할 수 없는 경우
- 안전 또는 정책 제약 조건이 명확하게 지정되지 않고 보상에서 적용 가능하지 않은 경우

'정답'을 가리킬 수 있는 경우 SFT를 사용합니다. 새로운 지식이 필요한 경우 RAG를 사용합니다. 견고한 기준과 강력하고 빠르며 악용하기 어려운 보상 함수가 있는 경우에만 RFT를 사용합니다.

지도 미세 조정(SFT)

감독 미세 조정은 태스크에 대해 사람이 레이블을 지정하는 입력과 출력 페어의 데이터셋을 기반으로 LLM을 훈련합니다. 올바른 응답이나 원하는 응답과 함께 프롬프트의 예제(질문, 지침 등)를 제공하고 이를 기반으로 모델을 계속 훈련합니다. 모델은 지도 손실(일반적으로 예측과 대상 출력 토큰 사이의 교차 엔트로피)를 최소화하도록 해당 가중치를 조정합니다. 이는 대부분의 지도 기계 학습 태스크에 사용되는 것과 동일한 훈련으로, LLM을 전문화하는 데 적용됩니다.

SFT는 지식이 아닌 동작을 변경합니다. 사전 훈련에서 나타나지 않았던 새로운 사실이나 전문 용어를 모델에 가르치지 않습니다. 모델에 알아야 할 내용이 아닌 어떻게 답변하는지를 가르칩니다. 새로운 도메인 지식(예: 내부 용어)이 필요한 경우 검색 증강 생성(RAG)을 사용하여 추론 시 해당 컨텍스트를 제공합니다. 그런 다음 SFT는 원하는 지침 준수 동작을 맨 위에 추가합니다.

작동 방식

SFT는 응답 토큰의 평균 교차 엔트로피 손실을 최소화하고 프롬프트 토큰을 컨텍스트로 처리하며 손실로부터 해당 정보를 마스킹하여 LLM을 최적화합니다. 모델은 대상 스타일, 구조 및 의사 결정 규칙을 내재화하여 각 프롬프트에 대해 올바른 완성 항목을 생성하는 방법을 학습합니다. 예를 들어 문서를 사용자 지정 카테고리로 분류하려면 프롬프트(문서 텍스트)와 레이블이 지정된 완성 항목(카테고리 레이블)으로 모델을 미세 조정합니다. 모델이 높은 확률로 각 프롬프트에 올바른 레이블을 출력할 때까지 해당 페어에서 훈련합니다.

몇백 개의 소수 예제만으로 SFT를 수행하다가 수십만 개로 스케일 업할 수 있습니다. SFT 샘플은 고품질이어야 하며 원하는 모델 동작에 맞게 직접 조정되어야 합니다.

SFT는 사용하는 경우

원하는 출력이 명확한 잘 정의된 태스크가 있는 경우 SFT를 사용합니다. 'X' 입력 제공, 올바른 출력은 'Y'라고 명시적으로 말할 수 있고 이러한 매핑의 예제를 수집할 수 있는 경우 지도 미세 조정이 적합합니다. SFT는 다음 시나리오에서 뛰어납니다.

- 구조화되거나 복잡한 분류 태스크 - 내부 문서 또는 계약을 여러 사용자 지정 카테고리로 분류합니다. SFT를 사용하면 모델은 프롬프트만 사용할 때보다 이러한 특정 카테고리를 훨씬 더 잘 학습할 수 있습니다.
- 알려진 답변이 있는 질문 답변 또는 변환 태스크 - 회사의 지식 베이스를 통해 질문에 답변하거나 각 입력에 올바른 응답이 있는 경우 여러 형식 사이에서 데이터를 변환하도록 모델을 미세 조정합니다.
- 형식 지정 및 스타일 일관성 - 올바른 형식이나 어조의 예제를 미세 조정하여 모델이 항상 특정 형식 또는 어조로 응답하도록 훈련합니다. 예를 들어 특정 브랜드 음성을 보여주는 프롬프트와 응답 페어에서 훈련하는 경우 해당 스타일로 출력을 생성하도록 모델을 가르칩니다. 지침 준수 동작은 종종 처음에 SFT를 통해 선별된 올바른 어시스턴트 동작 예제를 사용하여 학습됩니다.

SFT는 올바른 동작을 지정할 수 있는 경우 LLM에 새로운 기술이나 동작을 가르치는 가장 직접적인 방법입니다. 그리고 모델의 기존 언어 이해를 사용하고 태스크에 집중합니다. 모델이 특정 작업을 수행하도록 하고 예제 데이터셋을 생성하거나 생성할 수 있는 경우 SFT를 사용합니다.

원하는 동작을 밀접하게 미러링하는 고품질 프롬프트 및 응답 페어를 조합할 수 있는 경우 SFT를 사용합니다. 스키마, 함수 또는 도구 직접 호출, 모방이 적절한 훈련 신호인 구조화된 답변과 같은 명확한 대상이나 결정적 형식이 있는 태스크에 적합합니다. 목표는 동작을 구성하는 것입니다. 즉, 프롬프트를 태스크로 처리하고, 지침을 따르며, 어조 및 거부 정책을 채택하고, 일관된 형식을 생성하도록 모델을 가르칩니다. 원시 볼륨보다 데이터 품질, 일관성 및 중복 제거가 더 중요한 수백 개 이상의 데모를 계획

합니다. 직관적이고 비용 효율적인 업데이트를 위해 저순위 적응과 같은 파라미터 효율적 메서드를 사용하여 대부분의 백본을 그대로 유지하면서 소형 어댑터를 훈련합니다.

SFT를 사용하지 말아야 하는 경우

격차가 동작이 아닌 지식인 경우 SFT를 사용하지 마세요. 모델에 새로운 사실, 전문 용어 또는 최근 이벤트를 가르치지 않습니다. 이러한 경우 검색 증강 생성을 사용하여 추론 시 외부 지식을 가져옵니다. 품질을 측정할 수 있지만 하나의 올바른 답변에 레이블을 지정할 수 없는 경우 SFT를 사용하지 마세요. 확인 가능한 보상 또는 평가형 LLM로 강화 미세 조정을 사용하여 이러한 보상을 직접 최적화합니다. 요구 사항이나 콘텐츠가 자주 변경되는 경우 모델을 재훈련하는 대신 검색 및 도구 사용에 의존하세요.

주제

- [Nova Forge SDK](#)
- [제한된 인스턴스 그룹\(RIG\)을 포함하는 SageMaker HyperPod EKS 클러스터 생성](#)
- [Amazon SageMaker HyperPod 핵심 명령 가이드](#)
- [Nova Forge 액세스 및 설정](#)
- [Amazon Nova 모델에 대한 훈련](#)
- [훈련된 모델 평가](#)
- [MLflow를 사용하여 HyperPod 작업 모니터링](#)

Nova Forge SDK

Amazon Nova Forge SDK는 전체 Amazon Nova 모델 사용자 지정 수명 주기를 위한 프로그래밍 방식의 통합 인터페이스를 제공하는 포괄적인 Python SDK입니다. SDK는 Amazon SageMaker 및 Amazon Bedrock 플랫폼 전반에서 훈련, 평가, 모니터링, 배포 및 추론을 위한 단일의 일관된 API를 제공하여 모델 사용자 지정을 간소화합니다.

자세한 내용은 [Nova Forge SDK](#) 섹션을 참조하세요.

제한된 인스턴스 그룹(RIG)을 포함하는 SageMaker HyperPod EKS 클러스터 생성

Hyperpod에서 모델을 사용자 지정하려면 필요한 인프라를 설정해야 합니다. 제한된 인스턴스 그룹(RIG)으로 SageMaker HyperPod EKS 클러스터를 설정하는 방법에 대한 자세한 내용은 [워크숍](#)을 참조하세요. 여기에서 설정 프로세스에 대한 자세한 설명을 제공합니다.

Amazon SageMaker HyperPod 핵심 명령 가이드

Amazon SageMaker HyperPod는 훈련 워크플로를 관리하기 위한 광범위한 명령줄 기능을 제공합니다. 이 가이드에서는 클러스터 연결부터 작업 진행 상황 모니터링에 이르기까지 일반적인 작업에 필요한 명령을 다룹니다.

사전 조건

이러한 명령을 사용하기 전에 다음 설정을 완료했는지 확인합니다.

- RIG가 생성된 SageMaker HyperPod 클러스터(일반적으로 us-east-1)
- 훈련 아티팩트용으로 생성된 출력 Amazon S3 버킷
- 적절한 권한으로 구성된 IAM 역할
- 올바른 JSONL 형식으로 업로드된 훈련 데이터
- FSx for Lustre 동기화 완료(첫 번째 작업의 클러스터 로그에서 확인)

주제

- [레시피 CLI 설치](#)
- [클러스터에 연결](#)
- [훈련 작업 시작](#)
- [작업 상태 추적](#)
- [작업 로그 모니터링](#)
- [활성 작업 나열](#)
- [작업 취소](#)
- [평가 작업 실행](#)
- [일반적인 문제](#)

레시피 CLI 설치

설치 명령을 실행하기 전에 레시피 리포지토리의 루트로 이동합니다.

비Forge 사용자 지정 기법을 사용하는 경우 Hyperpodrecipes 리포지토리를 사용합니다. Forge 기반 사용자 지정의 경우 Forge 특정 레시피 리포지토리를 참조하세요.

다음 명령을 실행하여 SageMaker HyperPod CLI를 설치합니다.

Note

활성 conda/anaconda/miniconda 환경 또는 다른 가상 환경에 있지 않은지 확인합니다.
d그렇다면 다음을 사용하여 환경을 종료하세요.

- conda/anaconda/miniconda 환경의 경우 `conda deactivate`
- Python 가상 환경의 경우 `deactivate`

비Forge 사용자 지정 기법을 사용하는 경우 아래와 같이 `sagemaker-hyperpod-recipes`를 다운로드합니다.


```
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
```

Forge 구독자인 경우 아래 언급된 프로세스를 사용하여 레시피를 다운로드해야 합니다.

```
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**

pip install -e .를 실행하기 전에 [새 가상 환경](#) 사용하려면 다음을 실행합니다.

- python -m venv nova_forge
- source nova_forge/bin/activate
- 이제 명령줄에서 프롬프트 시작 위치에 (nova_forge)를 표시합니다.
- 이를 통해 CLI를 사용할 때 경쟁하는 종속 항목이 없도록 보장합니다.

목적: pip install -e .를 수행하는 이유는 무엇인가요?

이 명령은 SageMaker HyperPod CLI를 편집 가능한 모드로 설치하므로 매번 다시 설치하지 않고도 업데이트된 레시피를 사용할 수 있습니다. 또한 CLI가 자동으로 선택할 수 있는 새 레시피를 추가할 수 있습니다.

클러스터에 연결

작업을 실행하기 전에 SageMaker HyperPod CLI를 클러스터에 연결합니다.

```
export AWS_REGION=us-east-1 && SageMaker HyperPod connect-cluster --cluster-name  
<your-cluster-name> --region us-east-1
```

 Important

이 명령은 후속 명령에 필요한 컨텍스트 파일(/tmp/hyperpod_context.json)을 생성합니다. 이 파일을 찾을 수 없다는 오류가 표시되면 connect 명령을 다시 실행합니다.

전문가 팁: 다음과 같이 명령에 --namespace kubeflow 인수를 추가하여 항상 kubeflow 네임스페이스를 사용하도록 클러스터를 추가로 구성할 수 있습니다.

```
export AWS_REGION=us-east-1 && \  
hyperpod connect-cluster \  
--cluster-name <your-cluster-name> \  
--region us-east-1 \  
--namespace kubeflow
```

그러면 작업과 상호 작용할 때 모든 명령에 `-n kubeflow`를 추가하지 않아도 됩니다.

훈련 작업 시작

Note

PPO/RFT 작업을 실행하는 경우 모든 포드가 동일한 노드에서 예약되도록 레이블 선택기 설정을 `src/hyperpod_cli/sagemaker_hyperpod_recipes/recipes_collection/cluster/k8s.yaml`에 추가해야 합니다.

```
label_selector:
  required:
    sagemaker.amazonaws.com/instance-group-name:
      - <rig_group>
```

선택적 파라미터 재정의가 있는 레시피를 사용하여 훈련 작업을 시작합니다.

```
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"
}'
```

예상 결과:

```
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>"
}

```

작업 상태 추적

kubectl을 사용하여 실행 중인 작업을 모니터링합니다.

```
kubectl get pods -o wide -w -n kubeflow | (head -n1 ; grep <your-job-name>)
```

포드 상태 이해

다음 표에서는 다음과 같은 일반적인 포드 상태를 설명합니다.

Status	설명
Pending	수락되었지만 아직 노드에서 예약되지 않았거나 컨테이너 이미지가 풀링될 때까지 대기 중인 포드
Running	하나 이상의 컨테이너가 실행 중이거나 시작 중 상태인 노드에 바인딩된 포드
Succeeded	모든 컨테이너가 성공적으로 완료되었으며 다시 시작되지 않음
Failed	모든 컨테이너가 종료되었지만 하나 이상의 컨테이너가 실패로 종료됨
Unknown	포드 상태를 확인할 수 없음(일반적으로 노드 통신 문제로 인한 문제)

Status	설명
CrashLoopBackOff	컨테이너가 반복적으로 실패함, 재시작 시도에서 Kubernetes 백오프
ImagePullBackOff / ErrImagePull	레지스트리에서 컨테이너 이미지를 가져올 수 없음
OOMKilled	메모리 제한을 초과하여 컨테이너가 종료됨
Completed	작업 또는 포드가 성공적으로 완료됨(배치 작업 완료)

Tip

-w 플래그를 사용하여 포드 상태 업데이트를 실시간으로 감시합니다. Ctrl+C를 눌러 감시를 중지합니다.

작업 로그 모니터링

다음과 같은 세 가지 방법 중 하나로 로그를 볼 수 있습니다.

CloudWatch 사용

로그는 CloudWatch 아래 Hyperpodcluster가 포함된 AWS 계정에서 사용할 수 있습니다. 브라우저에서 보려면 계정의 CloudWatch 홈페이지로 이동하여 클러스터 이름을 검색합니다. 예를 들어 my-hyperpod-rig라는 클러스터가 있으면 로그 그룹에 다음과 같은 접두사가 붙습니다.

- 로그 그룹: /aws/sagemaker/Clusters/my-hyperpod-rig/{UUID}
- 로그 그룹에 있으면 hyperpod-i-00b3d8a1bf25714e4와 같은 노드 인스턴스 ID를 사용하여 특정 로그를 찾을 수 있습니다.
 - 여기서, i-00b3d8a1bf25714e4는 훈련 작업이 실행 중인 Hyperpod 친화적인 시스템 이름을 나타냅니다. 이전 명령 `kubectl get pods -o wide -w -n kubeflow | (head -n1 ; grep my-cpt-run)` 출력에서 NODE 열을 캡처한 방법을 떠올려 보세요.
 - 이 경우에 '마스터' 노드 실행은 hyperpod-i-00b3d8a1bf25714e4에서 실행되었으므로 해당 문자열을 사용하여 보려는 로그 그룹을 선택합니다. SagemakerHyperPodTrainingJob/rig-group/[NODE]라고 표시된 항목을 선택합니다.

CloudWatch Insights 사용

작업 이름이 유용하고 위의 모든 단계를 진행하지 않으려는 경우 `/aws/sagemaker/Clusters/my-hyperpod-rig/{UUID}`에서 모든 로그를 쿼리하여 개별 로그를 찾을 수 있습니다.

CPT:

```
fields @timestamp, @message, @logStream, @log
| filter @message like /(?!i)Starting CPT Job/
| sort @timestamp desc
| limit 100
```

작업 완료 시 `Starting CPT Job`을 `CPT Job completed`로 바꾸기

그런 다음 결과를 클릭하고 'Epoch 0'이라고 표시된 결과를 선택할 수 있습니다. 마스터 노드가 되기 때문입니다.

AWS CLI 사용

AWS CLI를 사용하여 로그를 테일링하도록 선택할 수 있습니다. 이렇게 하기 전에 `aws --version`을 사용하여 aws cli 버전을 확인하세요. 또한 터미널에서 라이브 로그를 추적하는 데 도움이 되는 이 유틸리티 스크립트를 사용하는 것이 좋습니다.

V1의 경우:

```
aws logs get-log-events \
--log-group-name /aws/sagemaker/YourLogGroupName \
--log-stream-name YourLogStream \
--start-from-head | jq -r '.events[].message'
```

V2의 경우:

```
aws logs tail /aws/sagemaker/YourLogGroupName \
--log-stream-name YourLogStream \
--since 10m \
--follow
```

활성 작업 나열

클러스터에서 실행 중인 모든 작업을 봅니다.


```
hyperpod list-jobs -n kubeflow
```

출력 예제:

```
{
  "jobs": [
    {
      "Name": "test-run-nhgza",
      "Namespace": "kubeflow",
      "CreationTime": "2025-10-29T16:50:57Z",
      "State": "Running"
    }
  ]
}
```

작업 취소

언제든지 실행 중인 작업을 중지합니다.

```
hyperpod cancel-job --job-name <job-name> -n kubeflow
```

작업 이름 찾기

옵션 1: 사용자 레시피에서

작업 이름은 레시피의 `run` 블록에 지정됩니다.

```
run:
  name: "my-test-run"                # This is your job name
  model_type: "amazon.nova-micro-v1:0:128k"
  ...
```

옵션 2: `list-jobs` 명령에서

`hyperpod list-jobs -n kubeflow`를 사용하고 출력에서 `Name` 필드를 복사합니다.

평가 작업 실행

평가 레시피를 사용하여 훈련된 모델 또는 기본 모델을 평가합니다.

사전 조건

평가 작업을 실행하기 전에 다음이 있는지 확인합니다.

- 훈련 작업 manifest.json 파일의 체크포인트 Amazon S3 URI(훈련된 모델의 경우)
- 올바른 형식으로 Amazon S3에 업로드된 평가 데이터세트
- 평가 결과에 대한 출력 Amazon S3 경로

Command

다음 명령을 실행하여 평가 작업을 시작합니다.

```
hyperpod start-job -n kubeflow \
  --recipe evaluation/nova/nova_2_0/nova_lite/
nova_lite_2_0_p5_48xl_gpu_bring_your_own_dataset_eval \
  --override-parameters '{
    "instance_type": "p5.48xlarge",
    "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-
HP-Eval-latest",
    "recipes.run.name": "<your-eval-job-name>",
    "recipes.run.model_name_or_path": "<checkpoint-s3-uri>",
    "recipes.run.output_s3_path": "s3://<your-bucket>/eval-results/",
    "recipes.run.data_s3_path": "s3://<your-bucket>/eval-data.jsonl"
  }'
```

파라미터 설명:

- recipes.run.name: 평가 작업의 고유 이름
- recipes.run.model_name_or_path: manifest.json 또는 기본 모델 경로의 Amazon S3 URI(예: nova-micro/prod)
- recipes.run.output_s3_path: 평가 결과의 Amazon S3 위치
- recipes.run.data_s3_path: 평가 데이터세트의 Amazon S3 위치

팁:

- 모델별 레시피: 각 모델 크기(micro, lite, pro)에는 자체 평가 레시피가 있습니다.
- 기본 모델 평가: 체크포인트 URI 대신 기본 모델 경로(예: nova-micro/prod)를 사용하여 기본 모델 평가

평가 데이터 형식

입력 형식(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"
}
```

출력 형식:

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

필드 설명:

- prompt: 모델로 전송된 형식 지정된 입력
- inference: 모델의 생성된 응답
- gold: 입력 데이터세트의 예상되는 정답
- metadata: 입력에서 전달되는 선택적 메타데이터

일반적인 문제

- `ModuleNotFoundError: No module named 'nemo_launcher':hyperpod_cli`가 설치된 위치에 따라 Python 경로에 `nemo_launcher`를 추가해야 할 수도 있습니다. 샘플 명령:

```
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'`은 `hyperpod connect cluster` 명령을 실행하지 못했음을 나타냅니다.

- 예약된 작업이 표시되지 않는 경우 SageMaker HyperPod CLI의 출력에 작업 이름 및 기타 메타데이터가 포함된 이 섹션이 있는지 다시 확인합니다. 그렇지 않은 경우 다음을 실행하여 헬름 차트를 다시 설치합니다.

```
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
```

Nova Forge 액세스 및 설정

작업과 함께 사용할 Amazon Nova Forge를 설정하려면 다음을 수행해야 합니다.

- Amazon Nova Forge 구독
- 클러스터 설정

주제

- [Amazon Nova Forge 구독](#)
- [인프라 설정](#)
- [책임 있는 AI](#)

Amazon Nova Forge 구독

Amazon Nova Forge 기능에 액세스하려면 다음 단계를 완료합니다.

1. AWS 계정에 대한 관리자 액세스를 확인하세요.
2. SageMaker AI 콘솔로 이동하여 [Amazon Nova Forge](#)에 대한 액세스를 요청하세요.
3. 구독 요청이 승인된 후 Amazon Nova 팀이 확인 이메일을 보낼 때까지 기다리세요.
4. 실행 역할에 `forge-subscription` 태그를 지정하세요. 이 태그는 Amazon Nova Forge 기능 및 체크포인트에 액세스하는 데 필요합니다. 실행 역할에 다음 태그를 추가하세요.
 - 키: `forge-subscription`
 - 값: `true`

Note

표준 Amazon Nova 기능은 Forge 구독 없이도 계속 사용할 수 있습니다. Amazon Nova Forge는 모든 모델 훈련 단계에서 제어 및 유연성을 갖춘 사용자 지정 경계 모델을 빌드하도록 설계되었습니다.

인프라 설정

Amazon Nova Forge 구독이 승인되면 Forge 지원 기능을 사용하는 데 필요한 인프라를 설정합니다. 제한된 인스턴스 그룹(RIG)으로 EKS 클러스터를 생성하는 방법에 대한 자세한 지침은 [워크숍 지침](#)을 따르세요.

책임 있는 AI

콘텐츠 조정 설정: Amazon Nova Forge 고객은 Amazon Nova Lite 1.0 및 Pro 1.0 모델의 사용자 지정 가능한 콘텐츠 조정 설정(CCMS)에 액세스할 수 있습니다. CCMS를 사용하면 특정 비즈니스 요구 사항에 맞게 콘텐츠 조정 제어를 조정하는 동시에 핵심적인 책임 있는 AI 보호를 유지 관리할 수 있습니다. 비즈니스 사용 사례가 CCMS에 적합한지 확인하려면 Amazon Web Services 계정 관리자에게 문의하세요.

Amazon Nova Forge는 Amazon Nova의 책임 있는 AI 지침에 맞게 모델을 조정하는 데 도움이 되는 훈련 데이터, 평가 벤치마크 및 런타임 제어가 포함된 책임 있는 AI 도구 키트를 제공합니다.

훈련 데이터: 데이터 혼합의 'RAI' 범주에는 책임 있는 AI 원칙, 안전 고려 사항 및 책임 있는 기술 배포를 강조하는 사례와 시나리오가 포함됩니다. 이를 사용하여 지속적인 사전 훈련 중에 모델을 책임감 있게 조정합니다.

평가: 벤치마크 태스크를 사용하여 부적절하거나 유해하거나 잘못된 콘텐츠를 감지 및 거부하는 모델의 기능을 테스트할 수 있습니다. 이러한 평가를 사용하여 기본 모델 성능과 사용자 지정 모델 성능의 차이를 측정합니다.

Amazon Nova 모델에 대한 훈련

SageMaker HyperPod에서 Amazon Nova 모델 훈련은 지속적인 사전 훈련(CPT), 지시 미세 조정(SFT), 강화 미세 조정(RFT)을 비롯한 여러 기법을 지원합니다. 각 기법은 다양한 사용자 지정 요구 사항을 충족하며 여러 Amazon Nova 모델 버전에 적용할 수 있습니다.

주제

- [지속적 사전 학습\(CPT\)](#)
- [지도 미세 조정\(SFT\)](#)
- [SageMaker HyperPod에서 강화 미세 조정\(RFT\)](#)

지속적 사전 학습(CPT)

지속적인 사전 훈련(CPT)은 파운데이션 모델의 사전 훈련 단계를 확장하여 특정 도메인 또는 코포라의 레이블이 지정되지 않은 추가 텍스트에 노출시키는 훈련 기법입니다. 레이블이 지정된 입력-출력 페어가 필요한 지도 미세 조정과 달리, CPT는 원시 문서에서 훈련하여 모델이 새 도메인에 대한 심층적인 지식을 얻고, 도메인별 용어 및 쓰기 패턴을 학습하며, 특정 콘텐츠 유형 또는 주제 영역에 적응할 수 있도록 지원합니다.

이 접근 방식은 법률 문서, 의학 문헌, 기술 문서 또는 독점 비즈니스 콘텐츠와 같은 도메인별 텍스트 데이터가 많고(수백억 개의 토큰)이고 모델이 해당 도메인에서 원어민 수준의 능숙도를 개발하기를 원하는 경우에 특히 유용합니다. 일반적으로 CPT 단계 이후에 모델이 새로 획득한 지식을 사용하고 유용한 태스크를 완료할 수 있도록 추가 명령 조정 단계를 거쳐야 합니다.

지원되는 모델

CPT는 다음과 같은 Amazon Nova 모델에서 사용할 수 있습니다.

- Nova 1.0(Micro, Lite, Pro)
- Nova 2.0(Lite)

Nova 1.0 및 Nova 2.0을 사용해야 하는 각각의 경우

Amazon Nova 모델 제품군은 정확도, 속도 및 비용 사이에서 최적화하기 위한 여러 가격 대비 성능 운영 지점을 제공합니다.

다음에 필요한 경우 Nova 2.0을 선택합니다.

- 복잡한 분석 태스크를 위한 고급 추론 기능
- 코딩, 수학 및 과학적 문제 해결에 대한 우수한 성능
- 더 긴 컨텍스트 길이 지원
- 더 나은 다국어 성능

Note

더 큰 모델이 항상 더 좋은 것은 아닙니다. Nova 1.0 및 Nova 2.0 모델 중에서 선택할 때 비용 대비 성능의 장단점과 특정 비즈니스 요구 사항을 고려합니다.

Nova 2.0에서 CPT

Amazon Nova Lite 2.0은 Nova Lite 1.0보다 더 크고 다양한 데이터세트에서 훈련된 모델입니다. Nova Lite 2.0은 더 큰 모델이지만 Nova Lite 1.0보다 더 빠른 추론을 제공하는 동시에, 향상된 추론 기능, 더 긴 컨텍스트 길이 및 향상된 다국어 성능을 제공합니다.

Nova 2.0에서 CPT를 사용하면 도메인별 데이터로 이러한 고급 기능을 확장하여 모델이 우수한 추론 및 분석 능력을 유지 관리하면서 전문 분야에 대한 심층적인 전문 지식을 개발할 수 있습니다.

샘플 CPT 레시피

다음은 CPT에 대한 레시피 샘플입니다. 이 레시피 및 기타 레시피는 [레시피](#) 리포지토리에서 찾을 수 있습니다.

```
# 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

```

2.0에서 CPT에 대한 데이터 준비

데이터 형식 요구 사항

훈련 및 검증 데이터세트는 아래 표시된 형식을 따르는 JSONL 파일이어야 하며, 각 줄에는 필수 필드 및 구조를 갖춘 대화를 나타내는 JSON 객체가 포함되어야 합니다. 다음 예를 참고하세요

```
{"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" }
```

텍스트 항목에는 대상 도메인을 잘 나타내는, 자연스럽게 흐르는 고품질의 콘텐츠가 포함되어야 합니다.

데이터가 [Arrow 형식](#)으로 변환될 수 있는지 테스트합니다. 아래 Python 스크립트를 사용하면 도움이 됩니다. 최소 datasets==2.18.0 버전이 사용되는지 확인합니다.

```
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)
```

JSONL 파일에 있는 것과 동일한 수의 줄을 인쇄해야 합니다.

데이터 혼합을 사용하는 경우 max_steps=2를 사용하여 첫 번째 작업을 실행합니다. 그러면 클러스터에서 데이터 액세스에 대한 최적화를 생성하고 모든 데이터 혼합을 사용할 수 있는지 검증할 수 있습니다.

CPT에 대한 데이터를 준비하는 방법

훈련 데이터는 지속적인 사전 훈련의 성공을 위한 가장 중요한 결정적인 요소입니다. CPT 데이터는 종종 'unlabeled'로 기술되지만 실제 의미는 훨씬 더 미묘합니다. 데이터의 구조화, 형식 지정 및 표시 방식에 따라 모델이 비즈니스 사용 사례에 필요한 지식과 기술을 획득하는지가 결정됩니다.

CPT에 대한 구조화된 비즈니스 데이터세트 준비

이는 도메인에 특화된 파운데이션 모델을 빌드하는 기업과 조직의 공통 과제입니다. 대부분의 비즈니스는 제품 카탈로그, 사용자 프로필, 트랜잭션 로그, 양식 제출, API 직접 호출, 운영 메타데이터 등 정형 데이터의 풍부한 리포지토리를 보유하고 있습니다. 처음에는 표준 사전 훈련에 일반적으로 사용되는 비정형 웹 텍스트와 매우 다르게 보입니다.

정형 비즈니스 데이터를 효과적으로 학습하려면 다운스트림 태스크에 대해 신중하게 생각하고 모델이 올바른 예측 관계를 학습하도록 데이터 프레젠테이션을 설계합니다.

지속적인 사전 훈련의 잠재력을 최대한 활용하려면 다음을 고려합니다.

- 추론 시 모델이 수행해야 하는 태스크
- 원시 데이터에 있는 정보
- 모델이 정보를 올바르게 추출하고 조작하는 방법을 학습하도록 해당 데이터를 정형화하는 방법

훈련에 정형 데이터를 가져오는 것만으로는 모델에서 해당 데이터로 추론하는 방법을 가르칠 수 없습니다. 모델이 학습하는 내용을 안내하기 위해 데이터 프레젠테이션을 적극적으로 구성합니다.

다음 섹션에는 데이터 증강의 중요성을 보여주는 문헌 자료를 검토합니다. 그리고 CPT에 대한 비즈니스 데이터세트를 처리하고 구성하는 방법에 대한 유용한 아이디어를 제공하는 정형 비즈니스 데이터에 대한 증강 전략 예제를 제공합니다.

문헌 자료에서 CPT에 대한 정형 데이터

CPT는 도메인 관련 사실을 모델에 패킹할 수 있지만 이 경우 종종 입력 또는 태스크가 이전될 때 해당 팩트를 검색하고 조작할 수 없습니다. 제어된 실험에 따르면, 사전 훈련 중에 다양한 증강이 없으면 모델이 나중에 지침 조정 후에도 추출하기 어려운 취약한 방식으로 사실을 기억하고 훈련 초기에 신호와 같은 지침을 주입하도록 권장합니다. 반정형 데이터의 경우 무작위 직렬화 및 기타 증강은 스키마 과적합을 줄입니다. 이 때문에 CPT를 먼저 실행하고 나중에 IFT를 실행하는 대신, CPT를 지침 스타일 태스크와 함께 사용해야 합니다. 재무 중심의 업무에서는 배치 시점에 CPT와 지침 데이터를 함께 혼합하면 일반화가 개선되고 순차 레시피에 비해 망각이 줄어듭니다. Qwen 기술 보고서는 고품질 지침 데이터를 사전 훈련 자체에 통합하여 동일한 패턴으로 수렴하므로 컨텍스트 학습이 향상되고 새로운 도메인 지식을 획득하는 동시에 다음 지침을 유지합니다.

반정형 코포라에 대해 데이터 증강이 핵심 요소입니다. 합성 그래프 인식 CPT는 추론 시점에 검색을 통해 관계와 합성물을 명시적으로 가르치는 엔터티 연결 코포라로 작은 도메인 세트를 확장합니다. 공동 CPT와 지침을 혼합하면 재무 분야에서 순차 파이프라인보다 뛰어난 성능을 제공하고, 일반 데이터와의 도메인 밸런싱을 통해 일반 기술에서 성능 저하를 줄입니다. 또한 대규모 도메인 CPT는 광범위한 기능을 유지하고 모델 병합을 통한 장단점을 허용할 수 있지만, 여전히 지침 조정을 필수적인 다음 단계로 가리켜 CPT 중에 명령 신호를 도입하는 가치를 강화합니다.

무작위화 및 셔플링을 통한 다양성 주입

정형 및 반정형 데이터세트에서 모델을 효과적으로 가르치는 데 도움이 되는 일반적인 전략은 데이터 세트의 필드 순서를 셔플링하고 일부 키를 무작위로 삭제하는 것입니다.

필드를 서포링하면 모델이 표시되는 위치 대신 각 값의 의미를 읽고 모든 필드 간의 관계를 학습합니다. 예를 들어 Amazon Store에 게시된 비디오 게임의 경우 '타이틀', '플랫폼', '가격', '상태', '에디션'이 서로 다른 순열로 도착하면 모델은 '세 번째 슬롯은 플랫폼'에 의존할 수 없습니다. 레이블을 값에 바인딩하고 속성 사이에서 쌍방 관계(제목 $\rightleftharpoons$ 플랫폼, 플랫폼 $\rightleftharpoons$ 가격, 상태 $\rightleftharpoons$ 가격)를 학습해야 합니다. 따라서 예를 들어 게임 이름과 관찰된 가격에서 가능한 플랫폼을 유추하거나 제목과 플랫폼이 주어지면 타당한 가격 범위를 추정할 수 있습니다.

직렬화 중에 키를 무작위로 삭제하는 경우 기능 드롭아웃처럼 작동합니다. 즉, 한 필드에 대한 공동 적응을 방지하고 강제로 모델이 나머지 증거에서 누락된 정보를 복구합니다. '플랫폼'이 없는 경우 모델은 제목 문자열 또는 호환성 텍스트에서 선택해야 합니다. '가격'이 숨겨져 있는 경우 플랫폼, 에디션 및 상태에서 삼각 관계를 활용해야 합니다. 이러한 방식으로 대칭($A \rightarrow B$ 및 $B \rightarrow A$), 복잡한 실제 목록에 대한 견고성 그리고 필드 누락, 필드 이름 변경 또는 필드 순서 변경 시 스키마 불변성을 구축합니다.

쇼핑 스타일 예제에서 이를 구체적으로 설명합니다. '제목: 'Elden Ring' | 플랫폼: PlayStation 5 | 상태: 중고 - 거의 새 제품 | 가격: \$34.99', '가격: \$34.99 | 제목: 'Elden Ring' | 상태: 중고 - 거의 새 제품 | 플랫폼: PlayStation 5'와 같은 순열처럼 동일한 항목을 여러 방법으로 직렬화합니다. 그리고 설명에서 'PS5와 호환 가능'을 그대로 두고 일부 방식에서 '플랫폼'을 삭제하여 전달합니다. {title, price}에서 플랫폼 예측 및 {title, platform}에서 가격 버킷 예측과 같은 보완적 목표를 훈련합니다. 키의 순서와 존재도 달라지기 때문에 유일하게 안정적인 전략은 토큰을 기억하지 않고 속성 간 실제 관계를 학습하는 것입니다.

중요한 데이터 표시 방식

LLM은 이미 확인한 내용을 바탕으로 다음 토큰을 예측하여 학습합니다. 따라서 훈련 중에 표시되는 필드 및 이벤트의 순서에 따라 모델이 학습할 수 있는 내용이 결정됩니다. 훈련 형식이 실제 태스크와 일치하면 정확한 의사 결정 토큰에서 손실이 발생합니다. 필드가 구조 없이 함께 전달되는 경우 모델은 바로 가기를 학습하거나 인기를 기억한 다음 옵션 중에서 선택하라는 메시지가 표시되면 실패합니다.

상황을 먼저 표시한 다음, 옵션과 의사 결정을 순차적으로 표시합니다. 모델이 결과나 설명에 대해서도 알고 있어야 하는 경우 의사 결정 후에 입력합니다.

CPT에 대한 샘플 패킹

패킹이란 무엇인가요?

창을 패딩이 아닌 실제 토큰으로 채우도록 여러 전체 예제로 훈련 데이터의 각 시퀀스 창을 채우는 것을 의미합니다.

이것이 중요한 이유

훈련 중 최대 컨텍스트 길이(예: 8,192개의 토큰)가 설정됩니다. 배치는 [배치 크기 × 컨텍스트 길이]로 형성됩니다. 훈련 예제가 컨텍스트 길이보다 짧으면 나머지 위치가 채워집니다(패딩). 패딩은 손실이 마스킹된 경우에도 여전히 어텐션과 MLP 커널을 통해 실행되므로 학습 신호를 전달하지 않는 토큰에 대해 컴퓨팅이 소모됩니다.

어떻게 패킹하나요?

여러 샘플을 패킹하려면 샘플의 전체 길이가 원하는 컨텍스트 길이 아래 포함되도록 [DOC] 구분 기호를 사이에 두고 여러 훈련 샘플을 연결합니다([DOC] 앞뒤에 공백 포함).

패킹된 문서 예제는 다음과 같습니다.

```
{"text": "training sample 1 [DOC] training sample 2 [DOC] training sample 3"}
```

CPT 파라미터 조정

CPT를 통해 미세 조정할 수 있는 파라미터는 다음과 같습니다.

실행 구성

- **name:** 훈련 작업을 설명하는 이름입니다. AWS Management Console에서 작업을 식별하는 데 도움이 됩니다.
- **model_type:** 사용할 Amazon Nova 모델 변형입니다. 사용할 수 있는 옵션은 `amazon.nova-2-lite-v1:0:256k`입니다.
- **model_name_or_path:** 훈련에 사용할 기본 모델의 경로입니다. 사용 가능한 옵션은 `nova-lite-2/prod` 또는 사후 훈련 체크포인트의 S3 경로(`s3://customer-escrow-bucket-unique_id/training_run_name`)입니다.
- **replicas:** 분산 훈련에 사용할 컴퓨팅 인스턴스의 수입니다. 사용 가능한 값은 선택한 모델에 따라 다릅니다. Amazon Nova Lite 2.0은 4개, 8개, 16개 또는 32개의 복제본을 지원합니다.
- **data_s3_path:** 훈련 데이터세트(JSONL 파일)의 S3 위치입니다. 이 파일은 클러스터와 동일한 AWS 계정 및 리전에 있어야 합니다. 제공된 모든 S3 위치는 동일한 계정 및 리전에 있어야 합니다.
- **validation_data_s3_path:** (선택 사항) 검증 데이터세트(JSONL 파일)의 S3 위치입니다. 이 파일은 클러스터와 동일한 계정 및 리전에 있어야 합니다. 제공된 모든 S3 위치는 동일한 계정 및 리전에 있어야 합니다.
- **output_s3_path:** 매니페스트 및 TensorBoard 로그가 저장되는 S3 위치입니다. 제공된 모든 S3 위치는 동일한 AWS 계정 및 AWS 리전에 있어야 합니다.

- `mlflow_tracking_uri`: MLFlow 로깅에 사용할 MLFlow 앱의 ARN
- `mlflow_experiment_name`: MLFlow 실험 이름
- `mlflow_run_name`: MLFlow 실행 이름

훈련 구성

- `max_length`: 토큰 단위의 최대 시퀀스 길이입니다. 이는 훈련을 위한 컨텍스트 창 크기를 결정합니다. CPT에 대해 지원되는 최대 값은 8,192개의 토큰입니다.

시퀀스가 길어지면 훈련 효율성이 향상되지만 메모리 요구 사항이 증가합니다. `max_length` 파라미터를 데이터 분포와 일치시키는 것이 좋습니다.

- `global_batch_size`: 모든 디바이스 및 워커에서 한 번의 순방향 또는 역방향 패스 동안 함께 처리되는 전체 훈련 샘플 수입니다.

이 값은 디바이스당 배치 크기와 디바이스 수를 곱한 값입니다. 이는 훈련의 안정성과 처리량에 영향을 미칩니다. 메모리 내에서 적절한 배치 크기로 시작하여 점진적으로 스케일 업하는 것이 좋습니다. 도메인별 데이터의 경우 배치 크기가 크면 그라디언트가 과도하게 평활화될 수 있습니다.

트레이너 설정

- `max_steps`: 실행할 훈련 단계 수입니다. 각 단계는 `global_batch_size`개의 요소를 사용하여 모델을 훈련합니다.

모델 설정

- `hidden_dropout`: 숨겨진 상태 출력이 삭제될 확률입니다. 작은 데이터세트에서 과적합을 줄이려면 이 값을 약 0.0~0.2 늘립니다. 유효한 값은 0~1입니다.
- `attention_dropout`: 어텐션 가중치가 삭제될 확률입니다. 이 파라미터는 일반화에 도움이 될 수 있습니다. 유효한 값은 0~1입니다.

옵티마이저 구성

- `lr`: 최적화 동안 단계 크기를 제어하는 학습률입니다. 성능 향상을 위해 $1e-6$ 에서 $1e-4$ 사이의 값을 권장합니다. 유효한 값은 0~1입니다.

- `name`: 옵티마이저 알고리즘입니다. 현재 `distributed_fused_adam`만 지원됩니다.
- `weight_decay`: L2 정규화 강도입니다. 값이 높을수록(0.01에서 0.1 사이) 정규화가 증가합니다.
- `warmup_steps`: 학습률을 점진적으로 높이는 단계 수입니다. 이는 훈련의 안정성을 향상시킵니다. 유효한 값은 1~20입니다.
- `min_lr`: 감소 종료 시의 최소 학습률입니다. 유효한 값은 0~1이지만 설정된 학습률보다 작아야 합니다.

지도 미세 조정(SFT)

SFT 훈련 프로세스는 다음과 같은 두 가지 주요 단계로 구성됩니다.

- 데이터 준비: 정해진 지침에 따라 데이터셋을 생성, 정리 또는 필요한 구조로 다시 포맷합니다. 입력, 출력 및 보조 정보(예: 추론 트레이스 또는 메타데이터)가 올바르게 조정되고 형식이 지정되었는지 확인합니다.
- 훈련 구성: 모델 훈련 방법을 정의합니다. Amazon SageMaker HyperPod를 사용하는 경우 이 구성은 다음을 포함하는 YAML 레시피 파일로 작성됩니다.
 - 데이터 소스 경로(훈련 및 검증 데이터셋)
 - 주요 하이퍼파라미터(에포크, 학습 속도, 배치 크기)
 - 선택적 구성 요소(분산 훈련 파라미터 등)

Nova 모델 비교 및 선택

Amazon Nova 2.0은 Amazon Nova 1.0보다 더 크고 다양한 데이터셋을 기반으로 훈련된 모델입니다. 주요 개선 사항에는 다음이 포함됩니다.

- 개선된 추론 기능: 명시적 추론 모드 지원 포함
- 더 광범위한 다국어 성능: 추가 언어에서 지원
- 복잡한 태스크에서 개선된 성능: 코딩 및 도구 사용 포함
- 확장된 컨텍스트 처리: 더 긴 컨텍스트 길이에서 정확도와 안정성 개선

Nova 1.0 및 Nova 2.0을 사용해야 하는 경우

다음과 같은 경우 Amazon Nova 2.0을 선택합니다.

- 고급 추론 기능을 갖춘 뛰어난 성능이 필요한 경우

- 다국어 지원 또는 복잡한 태스크를 처리해야 하는 경우
- 코딩, 도구 직접 호출 또는 분석 태스크에 대한 더 나은 결과가 필요한 경우

Nova 2.0에서 SFT

Amazon Nova Lite 2.0은 고급 추론 모드, 향상된 멀티모달 이해, 확장된 컨텍스트 처리 등 지도 미세 조정을 위한 향상된 기능을 제공합니다. Nova 2.0에서 SFT를 사용하면 복잡한 태스크에서 모델의 뛰어난 성능을 유지하면서 이러한 강력한 기능을 특정 사용 사례에 맞게 조정할 수 있습니다.

Nova 2.0에서 SFT의 주요 기능은 다음과 같습니다.

- 추론 모드 지원: 향상된 분석 기능에 대한 최종 답변 전에 명시적 추론 트레이스를 생성하도록 모델을 훈련합니다.
- 고급 멀티모달 훈련: 향상된 정확도로 문서 이해(PDF), 비디오 이해 및 이미지 기반 태스크를 미세 조정합니다.
- 도구 직접 호출 기능: 복잡한 워크플로에 대한 외부 도구 및 함수 직접 호출을 효과적으로 사용하도록 모델을 훈련합니다.
- 확장된 컨텍스트 지원: 문서 집약적인 애플리케이션의 안정성과 정확도를 높여 더 긴 컨텍스트 기간을 활용합니다.

Note

사용할 컨테이너 이미지 또는 레시피 예제에 대한 자세한 내용은 [Amazon Nova 레시피](#)를 참조하세요.

주제

- [추론 모드 선택\(Nova 2.0만 해당\)](#)
- [도구 직접 호출 데이터 형식](#)
- [문서 이해 데이터 형식](#)
- [SFT에 대한 비디오 이해](#)
- [데이터 업로드 지침](#)
- [미세 조정 작업 생성](#)
- [SFT 조정 파라미터](#)

- [하이퍼파라미터 지침](#)

샘플 SFT 레시피

다음은 SFT에 대한 샘플 레시피입니다. 이 레시피 및 기타 레시피는 [레시피](#) 리포지토리에서 찾을 수 있습니다.

```
run:
  name: my-full-rank-sft-run
  model_type: amazon.nova-2-lite-v1:0:256k
  model_name_or_path: nova-lite-2/prod
  data_s3_path: s3://my-bucket-name/train.jsonl # only and not compatible with
SageMaker Training Jobs
  replicas: 4 # Number of compute instances for
training, allowed values are 4, 8, 16, 32
  output_s3_path: s3://my-bucket-name/outputs/ # Output artifact path (HyperPod job-
specific; not compatible with standard SageMaker Training Jobs)
  mlflow_tracking_uri: "" # Required for MLFlow
  mlflow_experiment_name: "my-full-rank-sft-experiment" # Optional for MLFlow. Note:
leave this field non-empty
  mlflow_run_name: "my-full-rank-sft-run" # Optional for MLFlow. Note: leave
this field non-empty

training_config:
  max_steps: 100 # Maximum training steps. Minimal is 4.
  save_steps: ${oc.select:training_config.max_steps} # How many training steps the
checkpoint will be saved
  save_top_k: 5 # Keep top K best checkpoints. Note supported only
for jobs. Minimal is 1.
  max_length: 32768 # Sequence length (options: 8192, 16384, 32768
[default], 65536)
  global_batch_size: 32 # Global batch size (options: 32, 64, 128)
  reasoning_enabled: true # If data has reasoningContent, set to true;
otherwise False

  lr_scheduler:
    warmup_steps: 15 # Learning rate warmup steps. Recommend 15% of
max_steps
    min_lr: 1e-6 # Minimum learning rate, must be between 0.0 and
1.0

  optim_config:
    lr: 1e-5 # Optimizer settings
    # Learning rate, must be between 0.0 and 1.0
```



```

weight_decay: 0.0          # L2 regularization strength, must be between 0.0
and 1.0
adam_beta1: 0.9            # Exponential decay rate for first-moment
estimates
adam_beta2: 0.95          # Exponential decay rate for second-moment
estimates

peft:                      # Parameter-efficient fine-tuning (LoRA)
  peft_scheme: "null"      # Disable LoRA for PEFT

```

추론 모드 선택(Nova 2.0만 해당)

Amazon Nova 2.0은 향상된 분석 기능에 대한 추론 모드를 지원합니다.

- 추론 모드(활성화됨):
 - 훈련 구성에서 `reasoning_enabled: true` 설정
 - 최종 답변 전에 추론 트레이스를 생성하도록 모델 훈련
 - 복잡한 추론 태스크의 성능 개선
- 비추론 모드(비활성화됨):
 - `reasoning_enabled: false` 설정 또는 파라미터 생략(기본값)
 - 명시적 추론이 없는 표준 SFT
 - 단계별 추론의 이점을 얻지 못하는 태스크에 적합

Note

- 추론이 활성화되면 높은 수준의 추론 노력으로 작동합니다. SFT에는 낮은 추론 옵션이 없습니다.
- SFT에서 멀티모달 추론 콘텐츠는 지원되지 않습니다. 추론 모드는 텍스트 전용 입력에 적용됩니다.

비추론 데이터세트와 함께 추론 모드 사용

`reasoning_enabled: true`를 사용하여 비추론 데이터세트에서 Nova 훈련이 허용됩니다. 그러나 Amazon Nova는 주로 추론을 적용하지 않고 데이터에 표시된 응답을 생성하는 방법을 배우기 때문에 이 경우 모델이 추론 기능을 상실할 수 있습니다.

비추론 데이터세트에서 Amazon Nova를 훈련하지만 유추 중에 추론을 계속 사용하려는 경우:

1. 훈련 중 추론 비활성화(reasoning_enabled: false)
2. 추론 중 나중에 추론 활성화

이 접근 방식에서는 유추 시 추론을 허용하지만 추론이 없는 유추와 비교했을 때 성능 개선을 보장하지 않습니다.

모범 사례: 추론 데이터세트를 사용할 때는 훈련 및 유추 모두에 대한 추론을 활성화하고, 비추론 데이터세트를 사용할 때는 둘 다에 대해 추론을 비활성화합니다.

Note

사용할 컨테이너 이미지 또는 레시피 예제에 대한 자세한 내용은 [Amazon Nova 레시피](#)를 참조하세요.

도구 직접 호출 데이터 형식

SFT는 도구를 사용하기 위한 모델 훈련(함수 직접 호출)을 지원합니다. 다음은 도구 직접 호출에 대한 샘플 입력 형식입니다.

샘플 입력:

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

```

도구 직접 호출 데이터에 대한 중요 고려 사항:

- ToolUse는 어시스턴트 턴에만 표시되어야 함
- ToolResult는 사용자 턴에만 표시되어야 함
- ToolResult는 텍스트 또는 JSON 전용이어야 하며, 다른 양식은 현재 Amazon Nova 모델에서 지원되지 않음
- toolSpec 내 inputSchema는 유효한 JSON 스키마 객체여야 함
- 각 ToolResult는 이전 어시스턴트 ToolUse에서 유효한 toolUseId를 참조해야 하며, 이때 각 toolUseId는 대화당 정확히 한 번만 사용됨

Note

사용할 컨테이너 이미지 또는 레시피 예제에 대한 자세한 내용은 [Amazon Nova 레시피](#)를 참조하세요.

문서 이해 데이터 형식

SFT는 문서 이해 작업에 대해 모델 훈련을 지원합니다. 다음은 샘플 입력 형식입니다.

샘플 입력

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

```
}
```

문서 이해에 대한 중요 고려 사항:

- PDF 파일만 지원됨
- 최대 문서 크기는 10MB임
- 샘플에는 문서와 텍스트가 포함될 수 있지만, 문서를 다른 양식(예: 이미지 또는 비디오)과 혼합할 수는 없음

Note

사용할 컨테이너 이미지 또는 레시피 예제에 대한 자세한 내용은 [Amazon Nova 레시피](#)를 참조하세요.

SFT에 대한 비디오 이해

SFT는 비디오 이해 태스크에 대해 모델 미세 조정을 지원합니다. 다음은 샘플 입력 형식입니다.

샘플 입력

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

```

비디오 이해에 대한 중요 고려 사항:

- 비디오는 최대 50MB일 수 있음
- 비디오 길이는 최대 15분일 수 있음
- 샘플당 하나의 비디오만 허용되며 동일한 샘플에서 여러 비디오는 지원되지 않음
- 샘플에는 비디오와 텍스트가 포함될 수 있지만, 비디오를 다른 양식(예: 이미지 또는 문서)과 혼합할 수는 없음

Note

사용할 컨테이너 이미지 또는 레시피 예제에 대한 자세한 내용은 [Amazon Nova 레시피](#)를 참조하세요.

데이터 업로드 지침

훈련 및 검증 데이터세트를 S3 버킷에 업로드합니다. 레시피의 `run` 블록에서 다음 위치를 지정합니다.

```
## Run config
run:
  ...
  data_s3_path: "s3://<bucket-name>/<training-directory>/<training-file>.jsonl"
```

참고: <bucket-name>, <training-directory>, <validation-directory>, <training-file>, <validation-file>을 실제 S3 경로로 바꿉니다.

참고: 현재 검증 데이터세트는 Amazon Nova 2.0을 사용하는 SFT에 대해 지원되지 않습니다. 검증 데이터세트가 제공되면 무시됩니다.

미세 조정 작업 생성

`run` 블록의 `model_type` 및 `model_name_or_path` 필드를 사용하여 기본 모델을 정의합니다.

```
## Run config
run:
  ...
  model_type: amazon.nova-2-lite-v1:0:256k
  model_name_or_path: nova-lite-2/prod
  ...
```

SFT 조정 파라미터

SFT를 통해 조정할 수 있는 파라미터로 다음이 포함됩니다.

실행 구성

- `name`: 훈련 작업을 설명하는 이름입니다. AWS Management Console에서 작업을 식별하는 데 도움이 됩니다.
- `model_type`: 사용할 Amazon Nova 모델 변형입니다. 사용할 수 있는 옵션은 `amazon.nova-2-lite-v1:0:256k`입니다.
- `model_name_or_path`: 훈련에 사용할 기본 모델의 경로입니다. 사용 가능한 옵션은 `nova-lite-2/prod` 또는 사후 훈련 체크포인트의 S3 경로(`s3://customer-escrow-bucket-unique_id/training_run_name`)입니다.

- `replicas`: 분산 훈련에 사용할 컴퓨팅 인스턴스의 수입니다. 사용 가능한 값은 선택한 모델에 따라 다릅니다. Amazon Nova Lite 2.0은 4개, 8개, 16개 또는 32개의 복제본을 지원합니다.
- `data_s3_path`: 훈련 데이터세트(JSONL 파일)의 S3 위치입니다. 이 파일은 클러스터와 동일한 AWS 계정 및 리전에 있어야 합니다. 제공된 모든 S3 위치는 동일한 계정 및 리전에 있어야 합니다.
- `validation_data_s3_path`: (선택 사항) 검증 데이터세트(JSONL 파일)의 S3 위치입니다. 이 파일은 클러스터와 동일한 계정 및 리전에 있어야 합니다. 제공된 모든 S3 위치는 동일한 계정 및 리전에 있어야 합니다.
- `output_s3_path`: 매니페스트 및 TensorBoard 로그가 저장되는 S3 위치입니다. 제공된 모든 S3 위치는 동일한 AWS 계정 및 AWS 리전에 있어야 합니다.
- `mlflow_tracking_uri`: MLFlow 로깅에 사용할 MLFlow 앱의 ARN입니다.
- `mlflow_experiment_name`: MLFlow 실험 이름입니다.
- `mlflow_run_name`: MLFlow 실행 이름입니다.

훈련 구성

- `max_steps`: 실행할 훈련 단계 수입니다. 각 단계는 `global_batch_size`개의 요소를 사용하여 모델을 훈련합니다.
- `save_steps`: 훈련 중에 모델 체크포인트를 저장할 빈도(단계)입니다.
- `save_top_k`: 검증 지표를 기반으로 유지할 최적의 최대 체크포인트 수입니다.
- `max_length`: 토큰 단위의 최대 시퀀스 길이입니다. 이는 훈련을 위한 컨텍스트 창 크기를 결정합니다. SFT에 대해 지원되는 최대 값은 32,768개의 토큰입니다.

시퀀스가 길어지면 훈련 효율성이 향상되지만 메모리 요구 사항이 증가합니다. `max_length` 파라미터를 데이터 분포와 일치시키는 것이 좋습니다.

- `global_batch_size`: 모든 디바이스 및 워커에서 한 번의 순방향 또는 역방향 패스 동안 함께 처리되는 전체 훈련 샘플 수입니다.

이 값은 디바이스당 배치 크기와 디바이스 수를 곱한 값입니다. 이는 훈련의 안정성과 처리량에 영향을 미칩니다. 메모리 내에서 적절한 배치 크기로 시작하여 점진적으로 스케일 업하는 것이 좋습니다. 도메인별 데이터의 경우 배치 크기가 크면 그라디언트가 과도하게 평활화될 수 있습니다.

- `reasoning_enabled`: 훈련 중에 추론 기능을 활성화하는 부울 플래그입니다.

학습률 스케줄러

- `warmup_steps`: 학습률을 점진적으로 높이는 단계 수입니다. 이는 훈련의 안정성을 향상시킵니다.
- `min_lr`: 감소 종료 시의 최소 학습률입니다. 유효한 값은 0~1이지만 설정된 학습률보다 작아야 합니다.

옵티마이저 구성

- `lr`: 최적화 동안 단계 크기를 제어하는 학습률입니다. 성능 향상을 위해 $1e-6$ 에서 $1e-4$ 사이의 값을 권장합니다. 유효한 값은 0~1입니다.
- `weight_decay`: L2 정규화 강도입니다. 값이 높을수록(0.01에서 0.1 사이) 정규화가 증가합니다.
- `adam_beta1`: Adam 옵티마이저의 첫 번째 순간 추정치에 대한 지수 감소율입니다. 기본값은 0.9입니다.
- `adam_beta2`: Adam 옵티마이저의 두 번째 순간 추정치에 대한 지수 감소율입니다. 기본값은 0.95입니다.

PEFT 구성

- `peft_scheme`: 사용할 파라미터 효율 미세 조정 스키마입니다. 옵션은 전체 순위 미세 조정의 경우 `'null'` 또는 LoRA 기반 미세 조정의 경우 `lora`입니다.

LoRA 조정(`peft_scheme`이 `'lora'`인 경우)

- `alpha`: LoRA 조정 파라미터입니다. 하위 순위 적응의 크기를 제어합니다. 일반적 값은 8~128입니다.
- `lora_plus_lr_ratio`: LoRA+ 최적화에 대한 학습률입니다. 이 승수는 특별히 LoRA 파라미터에 대한 학습률을 조정합니다.

하이퍼파라미터 지침

훈련 접근 방식에 따라 다음과 같은 권장 하이퍼파라미터를 사용합니다.

전체 순위 훈련

- 에포크: 1
- 학습률(`lr`): $1e-5$
- 최소 학습률(`min_lr`): $1e-6$

저순위 적응(LoRA)

- 에포크: 2
- 학습률(lr): 5e-5
- 최소 학습률(min_lr): 1e-6

참고: 데이터세트 크기 및 검증 성능에 따라 이러한 값을 조정합니다. 훈련 지표를 모니터링하여 과적합을 방지합니다.

SageMaker HyperPod에서 강화 미세 조정(RFT)

강화 미세 조정은 정확히 올바른 답변으로 직접 감독하는 대신 응답 품질을 나타내는 피드백 신호(측정 가능한 점수 또는 보상)를 통해 모델 성능을 개선하는 기계 학습 기법입니다. 입력과 출력 페어로부터 학습하는 기존의 지도 미세 조정과 달리, RFT는 보상 함수를 사용하여 모델 응답을 평가하고 반복적으로 모델을 최적화하여 이러한 보상을 극대화합니다.

이 접근 방식은 정확히 올바른 출력을 정의하기 어려운 태스크에 특별히 효과적이지만 신뢰할 수 있는 방식으로 응답 품질을 측정할 수 있습니다. RFT를 사용하면 모델이 시험과 피드백을 통해 복잡한 행동과 선호도를 학습할 수 있으므로, 세심한 의사 결정, 창의적인 문제 해결 또는 프로그래밍 방식으로 평가할 수 있는 특정 품질 기준 준수가 필요한 애플리케이션에 적합합니다.

RFT는 사용하는 경우

명확하고 측정 가능한 성공 기준을 정의할 수 있지만 훈련에 정확히 올바른 출력을 제공하는 데 어려움을 겪는 경우 RFT를 사용합니다. 여러 개의 유효한 솔루션이 존재하지만 일부가 다른 솔루션보다 분명히 더 좋은, 창의적 쓰기, 코드 최적화 또는 복잡한 추론과 같이 품질이 주관적이거나 다면적인 작업에 적합합니다.

RFT는 다음과 같은 경우에 가장 잘 작동합니다.

- 프로그래밍 방식으로 모델 출력을 평가할 수 있는 신뢰할 수 있는 보상 함수가 있는 경우
- 모델 동작을 특정 기본 설정 또는 제약 조건에 맞게 조정해야 하는 경우
- 레이블이 지정된 고품질 예제를 수집하는 데 비용이 많이 들거나 이 방법이 실용적이지 않기 때문에 기존의 지도 미세 조정이 부족한 상황

반복된 개선, 개인화 또는 보상 신호로 인코딩될 수 있는 복잡한 비즈니스 규칙 준수가 필요한 애플리케이션의 경우 RFT를 고려합니다.

RFT가 가장 적합한 작업

RFT는 출력 품질을 객관적으로 측정할 수 있지만 최적의 응답을 미리 정의하기 어려운 도메인에서 뛰어납니다.

- 수학적 문제 해결: 여러 솔루션 경로로 확인 가능한 정확성
- 코드 생성 및 최적화: 테스트 가능한 실행 결과 및 성능 지표
- 과학적 추론 작업: 논리적 일관성 및 사실적 정확도
- 정형 데이터 분석: 프로그래밍 방식으로 확인 가능한 출력
- 여러 단계의 추론: 단계별 논리적 진행이 필요한 태스크
- 도구 사용 및 API 직접 호출: 실행 결과로 측정 가능한 성공
- 복잡한 워크플로: 특정 제약 조건 및 비즈니스 규칙 준수

RFT는 정확도, 효율성, 스타일과 같은 여러 경쟁 목표의 균형을 맞춰야 할 때 매우 효과적입니다.

RFT 훈련에 추론 모드를 사용해야 하는 경우

Amazon Nova 2.0은 RFT 훈련 중에 추론 모드를 지원합니다. 다음 모드를 사용할 수 있습니다.

- none: 추론 없음(reasoning_effort 필드 생략)
- low: 최소한의 추론 오버헤드
- high: 최대 추론 기능(reasoning_effort를 지정할 때 기본값)

Note

RFT에는 중간 옵션이 없습니다. 구성에 reasoning_effort 필드가 없으면 추론이 비활성화됩니다.

다음과 같은 경우 높은 수준의 추론을 사용합니다.

- 복잡한 분석 태스크
- 수학적 문제 해결
- 여러 단계의 논리적 연역
- 단계별 사고가 가치를 더하는 태스크

다음과 같은 경우에 none(reasoning_effort) 또는 낮은 수준의 추론을 사용합니다.

- 단순한 사실적 쿼리
- 직접 분류
- 속도 및 비용 최적화
- 간단한 질문과 답변

Important

더 높은 추론 모드일수록 훈련 시간과 비용, 추론 지연 시간 및 비용이 증가하지만 복잡한 추론 태스크에 대한 모델 기능도 증가합니다.

지원되는 모델

SageMaker HyperPod에서 RFT는 Amazon Nova Lite 2.0(`amazon.nova-2-lite-v1:0:256k`)을 지원합니다.

주요 단계

RFT 프로세스에는 다음과 같은 4개의 주요 단계가 포함됩니다.

- 평가자 구현: 보상 함수를 생성하여 품질 기준을 기반으로 모델 응답 점수를 프로그래밍 방식으로 매깁니다.
- 프롬프트 업로드: 평가를 위해 참조 데이터와 함께 지정된 대화형 형식으로 훈련 데이터를 준비하고 업로드합니다.
- 작업 시작: 구성된 파라미터를 사용하여 강화 미세 조정 프로세스를 시작합니다.
- 모니터링: 지표 대시보드를 통해 훈련 진행 상황을 추적하여 모델이 효과적으로 학습되도록 보장합니다.

각 단계는 이전 단계를 기반으로 빌드되며, 평가자는 일관된 피드백 신호를 제공하여 전체 훈련 프로세스를 안내하는 파운데이션 역할을 합니다.

주제

- [Nova 2.0에서 SFT](#)

Nova 2.0에서 SFT

RFT 훈련 데이터는 OpenAI 대화 형식을 따릅니다. 각 훈련 예제는 메시지, 참조 답변 및 선택적 도구 정의를 포함하는 JSON 객체입니다. 이 섹션에서는 Nova 2.0에서 RFT에 대한 효과적인 훈련 데이터를 준비하는 방법에 대한 지침을 제공합니다.

주제

- [데이터 형식 및 구조](#)
- [필드 설명](#)
- [하이퍼파라미터 지침](#)
- [추가 속성](#)
- [데이터세트 크기 권장 사항](#)
- [효과적인 훈련 데이터의 특성](#)
- [RFT 훈련 모니터링](#)

데이터 형식 및 구조

각 훈련 예제는 다음을 포함하는 JSON 객체입니다.

- **messages**: 시스템, 사용자 및 선택적으로 어시스턴트 역할을 사용하는 대화 턴 배열
- **reference_answer**: 보상 계산에 대한 평가 기준 또는 예상 출력
- **tools**(선택 사항): 모델에서 사용할 수 있는 함수 정의 배열
- **id**(선택 사항): 추적 및 중복 제거를 위한 고유 식별자

각 예제는 JSONL 파일에서 한 줄에 있어야 하며 한 줄에 하나의 JSON 객체가 있어야 합니다.

예제 1: 화학 문제

다음 예제에서는 실측 정보 값을 포함하는 참조 답변을 사용하는 화학 문제를 보여줍니다.

```
{
  "id": "chem-001",
  "messages": [
    {
      "role": "system",
      "content": "You are a helpful chemistry assistant"
    },
  ],
}
```

```
{
  "role": "user",
  "content": "Predict hydrogen bond donors and acceptors for this SMILES:
CCN(CC)CCC(=O)c1sc(N)nc1C"
},
"reference_answer": {
  "donor_bond_counts": 2,
  "acceptor_bond_counts": 4,
  "explanation": "Calculated using Lipinski's rule of five: N-H groups (2 donors), N
and O atoms with lone pairs (4 acceptors)"
}
}
```

Note

reference_answer에는 도메인별 규칙을 사용하여 계산된 실측 정보 값이 포함되어 있습니다. 보상 함수는 모델 예측 값을 이러한 참조 값과 비교하여 보상 점수를 계산합니다.

예제 2: 수학 문제

다음 예제에서는 해법 단계를 포함하는 수학 문제를 보여줍니다.

```
{
  "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": [" $2x = 13 - 5$ ", " $2x = 8$ ", " $x = 4$ "]
  }
}
```


예제 3: 도구 사용

다음 예제에서는 예상 동작이 있는 도구 사용을 보여줍니다.

```
{
  "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"
  }
}

```

필드 설명

필드	설명	추가 참고 사항	필수
id	이 RFT 예제의 고유 식별자	문자열(예: 'sample-001'). 추적 및 중복 제거에 유용합니다.	아니요
messages	프롬프트 및 컨텍스트를 정의하는 채팅 메시지의 정렬된 목록	객체의 배열입니다. 모델은 이를 순서대로 확인합니다. 일반적으로 시스템 메시지로 시작한 다음 사용자로 진행합니다.	예
messages[].role	메시지에서 화자	공통 값: 'system', 'user'(다른 컨텍스트에서 때때로 'assistant')	아니요
messages[].content	메시지의 텍스트 콘텐츠	일반 문자열. 시스템의 경우 지침, 사용자의 경우 태스크 또는 입력에 해당합니다.	아니요
도구	이 예제에서 모델에 사용할 수 있는 도구 사양	배열. 각 항목은 도구의 인터페이스와 메타데이터를 정의합니다. 유형으로 'function' 또는 'internal'이 포함될 수 있습니다.	아니요
reference_answer	이 예제의 예상 모델 출력	태스크에 따라 문자열 또는 객체에 해당합니다	아니요

필드	설명	추가 참고 사항	필수
		다. 평가 또는 훈련의 대상으로 사용됩니다.	

Note

추가 사용자 지정 필드(예: task_id, difficulty_level, context_data)는 검증되지 않으며 보상 함수에 메타데이터로 전달됩니다.

하이퍼파라미터 지침

훈련 접근 방식을 기반으로 다음과 같은 권장 하이퍼파라미터를 사용합니다.

일반:

- 에포크: 1
- 학습률(lr): 1e-7
- 세대 수: 8
- 최대 새 토큰 수: 8192
- 배치 크기: 256

저순위 적응(LoRA)

- LoRA 순위: 32

Note

데이터세트 크기 및 검증 성능에 따라 이러한 값을 조정합니다. 훈련 지표를 모니터링하여 과적합을 방지합니다.

추가 속성

'additionalProperties': true 설정을 사용하면 핵심 스키마 요구 사항 이외의 사용자 지정 필드를 포함할 수 있으므로 적절한 평가를 위해 보상 함수에 필요한 데이터를 유연하게 추가할 수 있습니다.

일반적인 추가 필드

다음과 같은 유형의 추가 필드를 포함할 수 있습니다.

메타데이터:

- `task_id`: 추적을 위한 고유 식별자
- `difficulty_level`: 문제 복잡성 지표
- `domain`: 주제 영역 또는 카테고리
- `expected_reasoning_steps`: 해법의 단계 수

평가 기준:

- `evaluation_criteria`: 특정 등급 루브릭
- `custom_scoring_weights`: 여러 측면의 상대적 중요도
- `context_data`: 문제에 대한 배경 정보
- `external_references`: 관련 설명서 또는 리소스에 대한 링크

추가 속성이 있는 예제

다음 예제에는 사용자 지정 메타데이터 필드가 포함되어 있습니다.

```
{
  "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
}

```

데이터세트 크기 권장 사항

시작점

다음과 같은 최소 데이터세트 크기로 시작합니다.

- 최소 100개의 훈련 예제
- 최소 100개의 평가 예제

모델 응답에서 일관되게 실행되는 신뢰할 수 있는 보상 함수와 고품질 입력 데이터의 우선순위를 지정합니다.

평가 우선 접근 방식

대규모 RFT 훈련에 투자하기 전에 모델의 기준 성능을 평가합니다.

- 높은 성능(> 95% 보상): RFT가 불필요할 수 있음 - 모델이 이미 잘 작동함
- 매우 낮은 성능(0% 보상): 먼저 SFT로 전환하여 기본 기능을 설정함
- 중간 성능: RFT가 적절할 가능성이 큼

이 평가 우선 접근 방식은 보상 함수에 버그가 없도록 보장하고 RFT가 사용 사례에 올바른 방법인지를 결정합니다. 소규모로 시작하여 RFT 워크플로에 익숙해지면서, 문제를 조기에 식별 및 수정하고, 스케일 업하기 전에 접근 방식을 검증하며, 보상 함수 신뢰성을 테스트할 수 있습니다. 검증 후에 더 큰 데이터세트로 확장하여 성능을 더욱 개선할 수 있습니다.

효과적인 훈련 데이터의 특성

명확성 및 일관성

좋은 RFT 예제에는 여러 모델 출력에서 정확한 보상을 계산할 수 있는 명확하고 모호하지 않은 입력 데이터가 필요합니다. 다음을 포함하여 데이터에서 노이즈를 방지합니다.

- 일관되지 않은 형식 지정
- 모순되는 레이블 또는 지침

- 모호한 프롬프트
- 참조 답변 충돌

모호할 경우 훈련 프로세스에서 오해가 발생하고 모델이 의도하지 않은 동작을 학습하게 됩니다.

다양성

데이터세트는 강력한 실제 성능을 보장하기 위해 프로덕션 사용 사례의 완전한 다양성을 캡처해야 합니다. 포함:

- 다양한 문제 유형 및 난이도
- 여러 입력 형식 및 엣지 케이스
- 모든 예상 시나리오의 대표 샘플

이러한 다양성은 과적합을 방지하는 데 도움이 되고 모델이 익숙하지 않은 입력을 정상적으로 처리하도록 보장합니다.

보상 함수 고려 사항

효율적인 훈련을 위해 보상 함수를 설계합니다.

- 분이 아닌 초 단위 내 실행
- Lambda를 사용하여 효과적으로 병렬 처리
- 일관되고 신뢰할 수 있는 점수 반환
- 여러 유형의 모델 출력을 정상적으로 처리

빠르고 확장 가능한 보상 함수를 사용하면 대규모로 신속한 반복과 비용 효율적인 실험이 가능합니다.

RFT 훈련 모니터링

훈련 중 주요 지표를 모니터링하여 효과적인 학습을 보장하고 잠재적 문제를 조기에 식별합니다.

주제

- [추적할 주요 지표](#)
- [RFT 이후 평가](#)
- [미세 조정 모델 사용](#)

- [제한 사항 및 모범 사례](#)
- [문제 해결](#)

추적할 주요 지표

훈련 중에 MIFlow를 사용하여 다음 지표를 모니터링합니다.

보상 지표:

- 평균 보상 점수: 모델 응답의 전반적인 품질(시간 경과에 따라 증가해야 함)
- 보상 분포: 높음, 중간, 낮음 수준의 보상을 받는 응답 비율
- 훈련 및 검증 보상 비교: 과적합 감지와 비교

훈련 지표:

- 정책 업데이트: 성공적인 가중치 업데이트 수
- 롤아웃 완료율: 성공적으로 평가된 샘플 비율

우려되는 패턴:

- 보상 정체(열악한 수준의 학습을 나타냄)
- 훈련 보상이 증가하는 동안 검증 보상 삭제(과적합)
- 시간 경과에 따라 크게 증가하는 보상 분산(불안정성)
- 높은 비율의 보상 함수 오류(구현 문제)

훈련을 중지하는 경우:

- 목표 성능 지표를 달성함
- 보상 정체 및 더 이상 개선되지 않음
- 검증 성능이 저하됨(과적합 감지됨)
- 최대 훈련 예산에 도달함

RFT 이후 평가

훈련이 완료되면 미세 조정된 모델을 평가하여 성능 개선을 평가합니다.

- RFT 평가 작업 실행: RFT 훈련의 체크포인트를 모델로 사용
- 기준과 비교: 동일한 테스트 세트에서 기본 모델과 미세 조정된 모델 모두 평가
- 지표 분석: 태스크별 지표(정확도, 보상 점수 등) 검토
- 정성적 검토 수행: 샘플 출력의 품질을 수동으로 검사

자세한 평가 절차는 평가 섹션을 참조하세요.

미세 조정 모델 사용

체크포인트에 액세스:

훈련이 완료되면 체크포인트를 찾습니다.

1. S3에서 output_path로 이동
2. output.tar.gz 다운로드 및 추출
3. manifest.json를 엽니다.
4. checkpoint_s3_bucket 값 복사

추론에 대한 배포:

추론 또는 추가 훈련을 위해 체크포인트 S3 경로를 사용합니다.

```
run:
  model_type: amazon.nova-2-lite-v1:0:256k
  model_name_or_path: "s3://customer-escrow-<account-number>-smtj-<unique-
  identifier>/<job-name>"
```

배포 및 추론 지침은 추론 섹션을 참조하세요.

제한 사항 및 모범 사례

현재 제한 사항:

베타 제한 사항:

- RFT에 대한 새 RIG 그룹을 생성해야 합니다. 이 제한 사항은 GA에서 해결될 예정입니다.
- 인스턴스 유형 요구 사항: P5 인스턴스(최소 8x P5.48xlarge)만 지원됩니다. 출시 예정: 더 작은 인스턴스 유형에 대한 지원(ETA: 2025년 1월 중순).

기능 제한 사항:

- 15분의 Lambda 제한 시간: 보상 함수는 15분 이내에 완료되어야 함
- 싱글턴만 - 멀티턴 대화는 지원되지 않음
- 검증 데이터세트: 훈련 중에는 지원되지 않습니다. 별도의 평가 작업을 사용하여 훈련 진행 상황을 평가합니다.

훈련 고려 사항:

- 낮은 보상 시나리오: 5% 미만의 예제에서 긍정적인 보상을 받을 때 어려움을 겪을 수 있음 - SFT 우선 고려
- 데이터 요구 사항: 효과적으로 학습하려면 충분한 다양성이 필요함
- 컴퓨팅 비용: 지도 미세 조정보다 비용이 많이 발생함

Nova Forge에서는 다음과 같은 제한 사항 중 일부가 제거되었습니다.

- 멀티턴 대화 지원
- 15분 제한 시간을 초과하는 보상 함수 허용
- 고급 알고리즘 및 조정 옵션 제공
- 복잡한 엔터프라이즈 사용 사례를 위해 설계되었으며, 특히 프론티어 모델을 빌드하도록 조정됨

모범 사례:

작게 시작한 다음 규모 조정:

- 최소 데이터세트(100~200개의 예제)와 소수의 훈련 에포크로 시작
- 스케일 업하기 전에 접근 방식 검증
- 결과를 기반으로 점진적으로 데이터세트 크기 및 훈련 단계 증가

SFT 우선 시 기준:

- 보상 점수가 지속적으로 낮은 경우(예: 항상 0) RFT 전에 SFT 수행
- 효과적으로 개선하려면 RFT에 합리적인 기준 성능이 필요함

효율적인 보상 함수 설계:

- 분이 아닌 초 단위 내 실행
- 외부 API 직접 호출 최소화
- 효율적인 알고리즘 및 데이터 구조 사용
- 적절한 오류 처리 구현
- 훈련 전에 철저하게 테스트
- Lambda의 병렬 조정 기능 활용

적극적으로 훈련 모니터링:

- 시간 경과에 따른 평균 보상 점수 추적
- 여러 샘플에서 보상 분포 감시
- 훈련 보상 및 검증 보상 비교
- 우려되는 패턴(정체, 과적합, 불안정) 감지

결과를 기반으로 반복:

- 여러 번 반복 후에도 보상이 개선되지 않으면 보상 함수 설계 조정
- 데이터세트 다양성을 늘려 더 명확한 학습 신호 제공
- 보상이 계속 0 근처로 유지되는 경우 SFT로 전환 고려
- 여러 하이퍼파라미터(학습 속도, 배치 크기)로 실험

데이터 품질 최적화:

- 다양한 대표 예제 보장
- 엣지 케이스 및 어려운 샘플 포함
- 보상 함수가 모든 예제 유형의 점수를 올바르게 매기는지 확인
- 보상 함수를 혼동하는 샘플 제거 또는 수정

문제 해결

보상 함수 오류:

증상: 훈련 중 보상 함수 직접 호출에서 높은 오류 비율

문제	증상	해결 방법
Lambda 제한 시간	15분 후 빈번한 제한 시간 초과	함수 성능 최적화, 복잡한 평가에 Nova Forge 고려
동시성 부족	Lambda 스로틀링 오류	lambda_concurrency_limit 증가 또는 할당량 증가 요청
휴호하지 않은 반환 형식	형식 오류와 함께 훈련 실패	반환 구조가 필수 인터페이스 형식과 일치하는지 확인
처리되지 않은 예외	간헐적 오류	포괄적인 오류 처리 및 로깅 추가
외부 API 실패	일관되지 않은 점수	재시도 로직 및 대체 전략 구현

훈련 성능 저하:

증상: 보상이 개선되지 않거나 낮은 값으로 정체됨

해결 방법:

- 보상 함수 정확성 확인: 알려진 좋은 예제 및 잘못된 예제로 테스트
- 기준 성능 확인: 기본 모델 평가, 정확도가 거의 0에 가까우면 SFT 우선 수행
- 데이터 다양성 증가: 여러 시나리오를 다루는 다양한 예제 더 추가
- 하이퍼파라미터 조정: 여러 학습률 또는 배치 크기 시도
- 보상 신호 품질 검토: 보상에서 좋은 응답과 나쁜 응답을 구별하는지 확인

과적합:

증상: 훈련 보상은 증가하지만 검증 보상은 감소함

해결 방법:

- 훈련 단계 축소: 조기에 훈련 중지
- 데이터세트 크기 증가: 훈련 예제 더 추가
- 정규화 추가: weight_decay 또는 entropy_coeff 조정
- 데이터 다양성 증가: 훈련 세트가 전체 분산을 나타내도록 보장

훈련된 모델 평가

평가 레시피는 Amazon Nova 모델 평가 작업이 어떻게 실행될지를 지정하는 YAML 구성 파일입니다. 이 레시피를 사용하면 공통 벤치마크 또는 사용자 지정 데이터세트를 기준으로 기본 모델 또는 학습된 모델의 성능을 평가할 수 있습니다. 평가 지표는 Amazon S3 또는 TensorBoard에 저장할 수 있습니다. 이 평가는 다양한 태스크에서 모델 성능을 정량적으로 측정하여 추가 사용자 지정 필요 여부를 판단하는 데 도움을 줍니다.

모델 평가는 고정된 벤치마크와 사전 정의된 정답을 기준으로 모델을 테스트하는 오프라인 프로세스입니다. 실시간 평가나 실제 사용자 상호작용을 통한 평가는 포함되지 않습니다. 실시간 평가가 필요한 경우, 모델을 Amazon Bedrock에 배포한 후 Amazon Bedrock 런타임 API를 호출하여 평가할 수 있습니다.

주제

- [사용 가능한 벤치마크 태스크](#)
- [레시피 파라미터 이해](#)
- [평가 레시피 예시](#)
- [평가 작업 시작](#)
- [평가 결과 액세스 및 분석](#)
- [RFT 평가](#)

사용 가능한 벤치마크 태스크

Amazon Nova에 대한 SageMaker AI 모델 평가 기능을 사용하여 벤치마크 지표를 계산하는 방법을 보여주는 샘플 코드 패키지를 사용할 수 있습니다. 코드 패키지에 액세스하려면 [sample-Nova-lighteval-custom-task](#)를 참조하세요.

다음은 지원되는 업계 표준 벤치마크 목록입니다. eval_task 파라미터에 다음 벤치마크를 지정할 수 있습니다.

벤치마크	양식	설명	Metrics	전략	하위 태스크 사용 가능
mmlu	텍스트	다중 태스크 언어 이해 - 57개 주제에	정확도	zs_cot	예

벤치마크	양식	설명	Metrics	전략	하위 태스크 사용 가능
		걸친 지식을 테스트합니 다.			
mmlu_pro	텍스트	MMLU - 전문 하위 세트 - 법 률, 의학, 회 계, 엔지니어 링 등 전문 분 야에 중점을 둡니다.	정확도	zs_cot	아니요
bbh	텍스트	고급 추론 태 스크 - 높은 수 준의 인지 능 력과 문제 해 결 능력을 테 스트하는 도 전적 문제의 모음입니다.	정확도	zs_cot	예
gpqa	텍스트	일반 물리학 질문 응답 - 물 리 개념 이해 와 관련 문제 해결 능력을 평가합니다.	정확도	zs_cot	아니요

벤치마크	양식	설명	Metrics	전략	하위 태스크 사용 가능
math	텍스트	수학적 문제 해결 - 대수학, 미적분학, 문 장제 문제 등 여러 주제에 서 수학적 추 론 능력을 측 정합니다.	exact_match	zs_cot	예
strong_reject	텍스트	품질 관리 태 스크 - 부적절 하거나 유해 하거나 잘못 된 콘텐츠를 감지하고 거 부하는 모델 의 능력을 테 스트합니다.	deflection	zs	예
IFEval	텍스트	지침 준수 평 가 - 모델이 주 어진 지침을 얼마나 정확 하게 따르고 요구 조건에 맞게 태스크 를 완료하는 지 측정합니 다.	정확도	zs	아니요

벤치마크	양식	설명	Metrics	전략	하위 태스크 사용 가능
gen_qa	텍스트	사용자 지정 데이터세트 평가 - 사용자가 자체 데이터세트를 가져와서 벤치마킹을 수행하고, ROUGE 및 BLEU와 같은 지표를 사용하여 모델 출력을 참조 답변과 비교합니다.	모두	gen_qa	아니요
llm_judge	텍스트	평가형 LLM 선호도 비교 - Amazon Nova Judge 모델을 사용하여 프롬프트에 대한 응답 페어 사이에서 선호도를 판별하여 (A를 기준으로 B 비교) B가 A보다 선호될 확률을 계산합니다.	모두	judge	아니요

벤치마크	양식	설명	Metrics	전략	하위 태스크 사용 가능
humaneval	텍스트	HumanEval - 대규모 언어 모델의 코드 생성 능력을 평가하도록 설계된 벤치마크 데이터 세트입니다.	pass@1	zs	아니요
mm_llm_judge	멀티모달(이미지)	이 새로운 벤치마크는 위의 텍스트 기반 llm_judge와 동일하게 동작합니다. 유일한 차이는 이미지 추론을 지원한다는 점입니다.	모두	judge	아니요

벤치마크	양식	설명	Metrics	전략	하위 태스크 사용 가능
rubric_llm_judge	Text	Rubric Judge는 Amazon Nova 2.0 Lite에 빌드된 향상된 평가형 LLM 평가 모델입니다. 기본 설정 결과만 제공하는 원래 평가 모델 과 달리 Rubric Judge는 각 프롬프트에 맞게 조정된 사용자 지정 평가 기준을 동적으로 생성하고 여러 차원에 세분화된 점수를 할당합니다.	모두	judge	아니요
aime_2024	Text	AIME 2024 - 고급 수학 추론 및 문제 해결을 테스트하는 미국 초대 수학 검사 문제	exact_match	zs_cot	No

벤치마크	양식	설명	Metrics	전략	하위 태스크 사용 가능
calendar_ scheduling	Text	Natural Plan - 여러 사람을 대상으로 여 러 날에 걸쳐 회의를 예약 할 수 있는 일 정 예약 태스 크 테스트 계 획 기능	exact_match	fs	No

다음 mmlu 하위 태스크를 사용할 수 있습니다.

```

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_macroconomics",
    "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"
]

```

다음 bbh 하위 태스크를 사용할 수 있습니다.

```

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"
]

```

다음 math 하위 태스크를 사용할 수 있습니다.

```

MATH_SUBTASKS = [
    "algebra",
    "counting_and_probability",
    "geometry",
    "intermediate_algebra",
    "number_theory",
    "prealgebra",
    "precalculus",
]

```

레시피 파라미터 이해

실행 구성

다음은 일반적인 실행 구성과 관련 파라미터에 대한 설명입니다.

```
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:** (필수) 평가 작업에 대한 설명이 포함된 이름입니다. AWS 콘솔에서 작업을 식별하는 데 도움이 됩니다.
- **model_type:** (필수) 사용할 Amazon Nova 모델 변형을 지정합니다. 이 필드는 수동으로 수정하지 마세요. 옵션에는 다음이 포함됩니다.
 - 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:** (필수) 기본 모델 경로 또는 훈련 후 체크포인트의 S3 경로입니다. 옵션에는 다음이 포함됩니다.
 - nova-micro/prod
 - nova-lite/prod
 - nova-pro/prod
 - nova-lite-2/prod
 - (훈련 후 체크포인트의 S3 경로) s3://<escrow bucket>/<job id>/outputs/checkpoints
- **replicas:** (필수) 분산 훈련에 사용할 컴퓨팅 인스턴스의 수입니다. 다중 노드는 지원되지 않으므로 이 값은 1로 설정해야 합니다.
- **data_s3_path:** (필수) 입력 데이터세트의 S3 경로입니다. 사용자 제공 데이터세트 또는 평가형 LLM 레시피를 사용하는 경우가 아니면 이 파라미터를 비워 둡니다.
- **output_s3_path:** (필수) 출력 평가 아티팩트를 저장할 S3 경로입니다. 출력 S3 버킷은 작업을 생성하는 계정과 동일한 계정에서 생성해야 합니다.
- **mlflow_tracking_uri:** (선택 사항) MLflow 실행/실험을 추적하기 위한 MLFlow 추적 서버 ARN. SageMaker AI 실행 역할에서 추적 서버에 액세스할 수 있는 권한이 있는지 확인하세요.

평가 구성

다음은 모델 평가 구성과 관련 파라미터에 대한 설명입니다.

```
evaluation:
  task: mmlu
  strategy: zs_cot
  subtask: mathematics
  metric: accuracy
```

- **task:** (필수) 사용할 평가 벤치마크 또는 태스크를 지정합니다.

지원되는 태스크 목록:

- 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:** (필수) 평가 접근 방식을 정의합니다.
 - **zs_cot:** 제로샷 생각의 사슬 - 명시적인 예시 없이, 단계별 추론을 수행하도록 대형 언어 모델에 지시하는 접근 방식입니다.
 - **zs:** 제로샷 - 사전 훈련 예시 없이 문제를 해결하는 접근 방식입니다.
 - **gen_qa:** 사용자 제공 데이터세트 레시피에 특화된 전략입니다.
 - **judge:** Amazon Nova 평가형 LLM 및 mm_llm_judge에 특정한 전략.

- **subtask:** (선택 사항, 제거 가능) 특정 평가 태스크에 대한 특정 하위 태스크를 지정합니다. 태스크에 하위 태스크가 없는 경우 레시피에서 이를 제거합니다.
- **metric:** (필수) 사용할 평가 지표입니다.
 - **accuracy:** 정답 비율입니다.
 - **exact_match:** (math 벤치마크의 경우) 입력 예측 문자열이 참조와 정확히 일치하는 비율을 반환합니다.
 - **deflection:** (strong reject 벤치마크의 경우) 기본 모델에 대한 상대 편향과 중요도 지표의 차이를 반환합니다.
 - **pass@1:** (humaneval 벤치마크의 경우) 모델의 최고 신뢰도 예측이 정답과 일치하는 사례의 비율을 측정하는 데 사용되는 지표입니다.
 - **all:** 다음 지표를 반환합니다.
 - **gen_qa** 및 사용자 제공 데이터세트 벤치마크의 경우 다음 지표를 반환합니다.
 - **rouge1:** 생성된 텍스트와 참조 텍스트 간의 유니그램(단일 단어) 중복을 측정합니다.
 - **rouge2:** 생성된 텍스트와 참조 텍스트 간의 바이그램(2개 연속 단어) 중복을 측정합니다.
 - **rougeL:** 텍스트 간에 가장 긴 공통 부분 수열을 측정하며, 일치 항목 간의 간격을 허용합니다.
 - **exact_match:** 생성된 텍스트가 문자별로 참조 텍스트와 정확히 일치하는지 여부를 나타내는 이진 점수(0 또는 1)입니다.
 - **quasi_exact_match:** **exact_match**와 유사하지만 일반적으로 대소문자, 구두점 및 공백 차이를 무시하는 더 관대한 일치 방식입니다.
 - **f1_score:** 정밀도와 재현율의 조화 평균으로, 예측된 답변과 참조 답변 간의 단어 중복을 측정합니다.
 - **f1_score_quasi:** **f1_score**와 유사하지만 사소한 차이를 무시하는 정규화된 텍스트 비교를 사용하는 더 관대한 일치 방식입니다.
 - **bleu:** 생성된 텍스트와 참조 텍스트 간의 n그램 일치 정밀도를 측정하며, 일반적으로 번역 평가에 사용됩니다.
 - **llm_judge** 및 **mm_llm_judge**의 경우 자체 제공 데이터세트 벤치마크를 가져오고 다음 지표를 반환합니다.
 - **a_scores:** 순방향 및 역방향 평가 패스에서 **response_A**가 승리한 횟수입니다.
 - **a_scores_stderr:** 쌍별 판단에서 **response_A scores**의 표준 오차입니다.
 - **b_scores:** 순방향 및 역방향 평가 패스에서 **response_B**가 승리한 횟수입니다.

- `ties`: `response_A`와 `response_B`가 동일한 것으로 평가되는 판단 수입니다.
- `ties_stderr`: 쌍별 판단에서 `ties`의 표준 오차입니다.
- `inference_error`: 올바르게 평가되지 못한 판단 수입니다.
- `inference_error_stderr`: 판단 간 추론 오류의 표준 오차입니다.
- `score`: `response_B`에 대한 순방향 및 역방향 패스의 승리 횟수에 기반한 집계 점수입니다.
- `score_stderr`: 쌍별 판단에서 집계 점수의 표준 오차입니다.
- `winrate`: Bradley-Terry 확률을 사용하여 계산된, `response_B`가 `response_A`보다 선호될 확률입니다.
- `lower_rate`: 부트스트랩 샘플링에서 추정된 승률의 하한(2.5번째 백분위수)입니다.

추론 구성

다음은 추론 구성과 관련 파라미터에 대한 설명입니다. 모든 파라미터는 선택 사항입니다.

```
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`: 생성할 최대 토큰 수입니다. 이는 정수여야 합니다.
- `top_k`: 고려할 확률이 가장 높은 토큰의 수입니다. 이는 정수여야 합니다.
- `top_p`: 토큰 샘플링을 위한 누적 확률 임계값입니다. 0.0~1.0 범위의 부동 소수점 수여야 합니다.
- `temperature`: 토큰 선택의 무작위성입니다. 값이 클수록 무작위성이 커집니다. 결과를 결정론적으로 만들려면 0을 사용합니다. 이 값은 최소값이 0인 부동 소수점 수여야 합니다.
- `top_logprobs`: 추론 응답에서 반환할 상위 logprobs 수. 이 값은 0~20의 정수여야 합니다. Logprobs에는 메시지 콘텐츠에서 반환된 각 출력 토큰의 고려된 출력 토큰 수와 로그 확률이 포함됩니다.
- `reasoning_effort`: 추론 가능 모델의 추론 동작을 제어합니다. `model_type`이 추론 가능 모델(현재 `amazon.nova-2-lite-v1:0:256k`)을 지정하는 경우에만 `reasoning_effort`를 설정합니다. 사용 가능한 옵션은 `null`(설정하지 않은 경우 기본값, 추론 비활성화), `low` 또는 `high`입니다.

humaneval의 경우 다음 추론 구성을 사용하는 것이 좋습니다.

```
inference:
  top_k: 1
  max_new_tokens: 1600
  temperature: 0.0
```

MLFlow 구성

다음은 MLFlow 구성 및 관련 파라미터에 대한 설명입니다. 모든 파라미터는 선택 사항입니다.

```
run:
  mlflow_tracking_uri: ""
  mlflow_experiment_name: ""
  mlflow_run_name: ""
```

- mlflow_tracking_uri: (선택 사항) MLflow 추적 서버의 위치(SMHP에만 필요)
- mlflow_experiment_name: (선택 사항) 관련 ML 실행을 그룹화하는 실험의 이름
- mlflow_run_name: (선택 사항) 실험 내 특정 훈련 실행의 사용자 지정 이름

평가 레시피 예시

Amazon Nova는 SageMaker HyperPod 레시피 GitHub 리포지토리에서 사용할 수 있는 네 가지 유형의 평가 레시피를 제공합니다.

일반 텍스트 벤치마크 레시피

이러한 레시피를 사용하면 광범위한 텍스트 전용 벤치마크 모음 전반에서 Amazon Nova 모델의 기본 기능을 평가할 수 있습니다. 이는 xxx_general_text_benchmark_eval.yaml 형식으로 제공됩니다.

사용자 제공 데이터세트 벤치마크 레시피

이러한 레시피를 사용하면 벤치마킹을 위한 자체 데이터세트를 가져와서 다양한 유형의 지표를 사용하여 모델 출력을 참조 답변과 비교할 수 있습니다. 이는 xxx_bring_your_own_dataset_eval.yaml 형식으로 제공됩니다.

다음은 사용자 제공 데이터세트 요구 사항입니다.

- 파일 형식 요구 사항
 - 평가 예시가 포함된 단일 `gen_qa.jsonl` 파일을 포함해야 합니다.
 - SageMaker 훈련 작업이 액세스할 수 있는 S3 위치에 데이터세트를 업로드해야 합니다.
 - 파일은 일반 Q&A 데이터세트에 필요한 스키마 형식을 따라야 합니다.
- 스키마 형식 요구 사항 - JSONL 파일의 각 줄은 다음 필드가 있는 JSON 객체여야 합니다.
 - `query`: (필수) 답변이 필요한 질문 또는 지침이 포함된 문자열
 - `response`: (필수) 예상 모델 출력을 포함하는 문자열
 - `system`: (선택 사항) 쿼리를 처리하기 전에 AI 모델의 동작, 역할 또는 특성을 설정하는 시스템 프롬프트가 포함된 문자열
 - `metadata`: (선택 사항) 태그 지정에 위해 항목과 연결된 메타데이터를 포함하는 문자열.

다음은 사용자 제공 데이터세트 예시 항목입니다.

```
{
  "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"
}
```

사용자 지정 데이터세트를 사용하려면 다음 필수 필드를 포함하도록 평가 레시피를 수정합니다. 콘텐츠는 변경하지 마세요.

```
evaluation:
  task: gen_qa
  strategy: gen_qa
```

```
metric: all
```

다음과 같은 제한이 적용됩니다.

- 평가당 하나의 JSONL 파일만 허용됩니다.
- 파일은 정의된 스키마를 엄격하게 따라야 합니다.
- 컨텍스트 길이 제한: 데이터세트의 각 샘플에서, 컨텍스트 길이(시스템 + 쿼리 프롬프트 포함)는 3.5k 미만이어야 합니다.

평가형 Nova LLM 벤치마크 레시피

평가형 Amazon Nova LLM은 고객이 사용자 지정 데이터세트에서 한 모델의 응답 품질을 기준 모델 응답과 비교하는 모델 평가 기능입니다. 프롬프트, 기준 응답 및 도전자 응답이 있는 데이터세트를 가져 오고 Amazon Nova Judge 모델을 사용하여 페어별 비교를 통해 [Bradley-Terry 확률](#)로 승률 지표를 제공합니다.

이 레시피는 xxx_llm_judge_eval.yaml 형식으로 제공됩니다.

다음은 평가형 LLM 요구 사항입니다.

- 파일 형식 요구 사항
 - 평가 예시가 포함된 단일 llm_judge.jsonl 파일을 포함합니다. 파일 이름은 llm_judge.jsonl이어야 합니다.
 - [SageMaker HyperPod RIG](#)가 액세스할 수 있는 S3 위치에 데이터세트를 업로드해야 합니다.
 - 파일은 llm_judge.jsonl 데이터세트에 필요한 스키마 형식을 따라야 합니다.
 - 입력 데이터세트는 모든 레코드가 12k 컨텍스트 길이 미만인지 확인해야 합니다.
- 스키마 형식 요구 사항 - JSONL 파일의 각 줄은 다음 필드가 있는 JSON 객체여야 합니다.
 - prompt: (필수) 생성된 응답에 대한 프롬프트가 포함된 문자열입니다.
 - response_A: 기준 응답을 포함하는 문자열입니다.
 - response_B: 기준 응답과 비교할 대체 응답을 포함하는 문자열입니다.

다음은 평가형 LLM 예시 항목입니다.

```
{
  "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."
}

```

사용자 지정 데이터셋을 사용하려면 다음 필수 필드를 포함하도록 평가 레시피를 수정합니다. 콘텐츠는 변경하지 마세요.

```

evaluation:
  task: llm_judge
  strategy: judge
  metric: all

```

다음과 같은 제한이 적용됩니다.

- 평가당 하나의 JSONL 파일만 허용됩니다.
- 파일은 정의된 스키마를 엄격하게 따라야 합니다.
- Amazon Nova Judge 모델은 모든 모델 패밀리 사양(즉, Lite, Micro, Pro)에서 동일합니다.
- 사용자 지정 판단 모델은 현재 지원되지 않습니다.
- 컨텍스트 길이 제한: 데이터셋의 각 샘플에서, 컨텍스트 길이(시스템 + 쿼리 프롬프트 포함)는 7k 미만이어야 합니다.

멀티모달(이미지) 벤치마크 레시피에 대한 Nova 평가형 LLM

Amazon Nova MM_LLM Judge라고 하는 멀티모달에 대한 Nova LLM Judge(이미지)는 사용자 지정 데이터세트를 사용하여 한 모델의 응답 품질을 기존 모델의 응답과 비교하는 모델 평가 기능입니다. 프롬프트, 기존 응답, 도전자 응답, Base64로 인코딩된 문자열 양식의 이미지가 있는 데이터세트를 수락하고 Amazon Nova Judge 모델을 사용하여 페어별 비교를 통해 [Bradley-Terry](#) 확률에 기반한 승률 지표를 제공합니다. 레시피 형식: `xxx_mm_llm_judge_eval.yaml`.

Nova LLM 데이터세트 요구 사항

파일 형식:

- 평가 예시가 포함된 단일 `mm_llm_judge.jsonl` 파일입니다. 파일 이름은 정확히 `llm_judge.jsonl`이어야 합니다.
- 데이터세트는 SageMaker 훈련 작업에서 액세스할 수 있는 S3 위치에 업로드해야 합니다.
- 파일은 `mm_llm_judge` 데이터세트에 필요한 스키마 형식을 따라야 합니다.
- 입력 데이터세트에서는 이미지 속성을 제외하고 모든 레코드가 12k 컨텍스트 길이 미만인 되도록 보장해야 합니다.

스키마 형식 - `.jsonl` 파일의 각 줄은 다음 필드가 있는 JSON 객체여야 합니다.

필수 필드:

`prompt`: 생성된 응답에 대한 프롬프트가 포함된 문자열입니다.

`images`: 데이터 속성(Base64로 인코딩된 이미지 문자열)이 있는 객체 목록을 포함하는 배열.

`response_A`: 기존 응답을 포함하는 문자열입니다.

`response_B`: 기존 응답과 비교할 대체 응답을 포함하는 문자열입니다.

입력 예

가독성을 위해 다음 예제에는 새 줄과 들여쓰기가 포함되지만 실제 데이터세트에서는 각 레코드가 한 줄에 있어야 합니다.

```
{
  "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",
}
```

사용자 지정 데이터셋을 사용하려면 다음 필수 필드를 포함하도록 평가 레시피를 수정합니다. 콘텐츠를 변경하지 마세요.

```
evaluation:
  task: mm_llm_judge
  strategy: judge
  metric: all
```

제한 사항

- 평가당 하나의 .jsonl 파일만 허용됩니다.
- 파일은 정의된 스키마를 엄격하게 따라야 합니다.
- Nova MM Judge 모델은 이미지 참조만 지원합니다.
- Nova MM Judge 모델은 Amazon Nova Lite 사양에서 동일합니다.
- (현재 사용자 지정 구분 기호는 지원되지 않습니다.)
- Amazon S3 이미지 URI는 지원되지 않습니다.
- 입력 데이터셋에서는 이미지 속성을 제외하고 모든 레코드가 12k 컨텍스트 길이 미만인 되도록 보장해야 합니다.

Rubric 기반 평가

Rubric Judge는 Amazon Nova 2.0 Lite에 빌드된 향상된 평가형 LLM 평가 모델입니다. 기본 설정 결정(A>B, B>A 또는 동등)만 제공하는 [원래 평가 모델](#)과 달리 Rubric Judge는 각 프롬프트에 맞게 조정된 사용자 지정 평가 기준을 동적으로 생성하고 여러 차원에 세분화된 점수를 할당합니다.

주요 기능:

- 동적 기준 생성: 입력 프롬프트를 기반으로 관련 평가 차원 자동 생성
- 가중치 기반 점수: 상대적 유의성을 반영하기 위해 각 기준에 중요도 가중치 할당
- 세분화된 평가: 각 기준에 대해 바이너리(true/false) 또는 스케일(1~5) 기준으로 세부 점수 제공
- 품질 지표: 응답 간 차이의 정도를 정량화하는 연속 품질 점수(스케일: 0~1) 계산

모델에서 생성된 기준 예제:

```
price_validation:
  description: "The response includes validation to ensure price is a positive value."
  type: "scale"
  weight: 0.3
```

모델은 생성된 모든 기준에 대해 두 응답을 모두 평가한 다음, 이러한 기준 수준 점수를 사용하여 최종 기본 설정 결정을 알립니다.

주제

- [레시피 구성](#)
- [입력 데이터세트 형식](#)
- [평가 출력](#)
- [추론 모델 지원](#)

레시피 구성

Rubric Judge 레시피

레시피에서 task: rubric_llm_judge를 설정하여 Rubric Judge를 활성화합니다.

```
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)

```

원래 평가형 LLM 레시피(비교용)

원래 평가 모델은 task: llm_judge를 사용합니다.

```

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)

```

입력 데이터세트 형식

입력 데이터세트 형식은 [원래 결정 모델](#)과 동일합니다.

필수 필드:

- **prompt**: 입력 프롬프트 및 지침을 포함하는 문자열
- **response_A**: 기준 모델 출력을 포함하는 문자열
- **response_B**: 사용자 지정된 모델 출력을 포함하는 문자열

데이터세트 예제(JSONL 형식):

```

{"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."
}
```

형식 지정 요구 사항

- 각 항목은 한 줄의 JSON 객체여야 함
- 항목을 새 줄로 구분
- 예제와 같이 정확한 필드 이름 지정 준수

평가 출력

출력 구조

Rubric Judge는 원래 결정 모델에 비해 향상된 평가 지표를 생성합니다.

```
{
  "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"
}
}

```

Rubric Judge의 새 지표

다음과 같은 6개의 지표는 Rubric Judge에 고유하며 세분화된 품질 평가를 제공합니다.

지표	설명
weighted_score_A	모델에서 생성된 모든 평가 기준에서 response_A에 대해 정규화된 평균 품질 점수. 점수에는 기준 중요도에 따라 가중치가 부여되고 점수는 0~1의 스케일로 정규화됩니다(높은 값 = 더 나은 품질).
weighted_score_A_stderr	weighted_score_A 평균의 표준 오차로, 통계적 불확실성을 나타냄
weighted_score_B	모델에서 생성된 모든 평가 기준에서 response_B에 대해 정규화된 평균 품질 점수. 점수에는 기준 중요도에 따라 가중치가 부여되고 점수는 0~1의 스케일로 정규화됩니다(높은 값 = 더 나은 품질).

지표	설명
weighted_score_B_stderr	weighted_score_B 평균의 표준 오차로, 통계적 불확실성을 나타냄
score_margin	가중치 적용 점수 간 차이(weighted_score_A - weighted_score_B로 계산됨). 범위: -1.0~1.0. 양수 = response_A가 더 좋음, 음수 = response_B가 더 좋음, 0에 가까운 값 = 유사한 품질
score_margin_stderr	score_margin 평균의 표준 오차로, 품질 차이 측정의 불확실성을 나타냄

가중치 기반 점수 지표 이해

목적: 가중치 기반 점수는 바이너리 기본 설정 결정을 보완하는 지속적인 품질 측정을 제공하여 모델 성능에 대한 심층적인 인사이트를 제공합니다.

원래 평가와의 주요 차이:

- 원래 평가: 개별 기본 설정($A > B$, $B > A$, $A = B$)만 출력
- Rubric Judge: 사용자 지정 기준에 따라 기본 설정과 연속 품질 점수(스케일: 0~1) 모두 출력

Interpreting score_margin:

- score_margin = -0.128: Response_B 점수가 response_A보다 12.8% 더 높음
- |score_margin| < 0.1: 품질 차이가 적음(근사한 결정)
- |score_margin| > 0.2: 명확한 품질 차이(신뢰할 수 있는 결정)

사용 사례:

- 모델 개선: 모델 성능이 저하되는 특정 영역 식별
- 품질 정량화: 승률과 함께 성능 격차의 크기 측정
- 신뢰도 평가: 근사한 결정과 명확한 품질 차이 구분

⚠ Important

최종 결정은 여전히 판단 모델의 명시적 기본 설정 레이블을 기반으로 하여 전체적인 추론을 보존하고 전진/후진 평가를 통해 적절한 위치 편향 완화를 보장합니다. 가중치 적용 점수는 기본 결정을 대체하는 것이 아니라 관찰성 도구 역할을 합니다.

계산 방법

가중치 적용 점수는 다음 프로세스를 통해 계산됩니다.

- 기준 데이터 추출: 평가의 YAML 출력을 구문 분석하여 기준 점수 및 가중치 추출
- 점수 정규화:
 - 스케일 유형 기준(1~5): $(\text{score} - 1) / 4$ 를 계산하여 0~1로 정규화
 - 이진 기준(true/false): 1.0/0.0으로 변환
- 가중치 적용: 정규화된 각 점수에 기준 가중치를 곱함
- 집계: 각 응답에 대한 모든 가중치 적용 점수를 합함
- 마진 계산: $\text{score\_margin} = \text{weighted\_score\_A} - \text{weighted\_score\_B}$ 계산

예제: response_A의 가중치 합계가 0.65이고 response_B의 가중치 합계가 0.78인 경우 score_margin은 -0.13입니다. 즉, response_B가 모든 가중치 적용 기준에서 품질이 13% 더 높음을 나타냅니다.

추론 모델 지원

추론 모델 지원을 사용하면 최종 응답을 생성하기 전에 명시적인 내부 추론을 수행하는 추론 가능 Amazon Nova 모델을 사용하여 평가할 수 있습니다. 이 기능은 reasoning_effort 파라미터를 통한 API 수준 제어를 사용하여 추론 기능을 동적으로 활성화하거나 비활성화함으로써 복잡한 분석 태스크에 대한 응답 품질을 개선할 수 있습니다.

지원되는 모델:

- amazon.nova-2-lite-v1:0:256k

레시피 구성

레시피의 inference 섹션에 reasoning_effort 파라미터를 추가하여 추론을 활성화합니다.

```

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)

```

reasoning_effort 파라미터 사용

reasoning_effort 파라미터는 추론 가능 모델의 추론 동작을 제어합니다.

사전 조건:

- 모델 호환성: model_type이 추론 가능 모델(현재 amazon.nova-2-lite-v1:0:256k)을 지정하는 경우에만 reasoning_effort를 설정함

- 오류 처리: 지원되지 않는 모델과 함께 `reasoning_effort`를 사용하면 `ConfigValidationError: "Reasoning mode is enabled but model '{model_type}' does not support reasoning. Please use a reasoning-capable model or disable reasoning mode."`에서 실패함

사용 가능한 옵션:

옵션	동작	토큰 제한	사용 사례
<code>null</code> (기본값)	추론 모드 비활성화	해당 사항 없음	추론 오버헤드가 없는 표준 평가
<code>low</code>	제약 조건과의 추론 활성화	내부 추론을 위한 4,000개의 토큰	간결한 추론이 필요한 시나리오, 속도와 비용에 맞게 최적화
높음	제약 조건 없이 추론 활성화	내부 추론에 대한 토큰 제한 없음	광범위한 분석 및 단계별 추론이 필요한 복잡한 문제

추론을 활성화하는 경우

다음과 같은 경우 추론 모드(**low**, **medium** 또는 **high**)를 사용합니다.

- 복잡한 문제 해결 태스크(수학, 논리적 퍼즐, 코딩)
- 중간 추론이 필요한 다단계 분석 질문
- 자세한 설명 또는 단계별 사고로 정확도가 향상되는 태스크
- 응답 품질이 속도보다 우선되는 시나리오

다음과 같은 경우 비추론 모드(파라미터 생략)를 사용합니다.

- 간단한 Q&A 또는 실제 쿼리
- 창의적 쓰기 태스크
- 더 빠른 응답 시간이 중요한 경우
- 추론 오버헤드를 제외해야 하는 성능 벤치마킹

- 추론으로 태스크 성능이 개선되지 않는 경우 비용 최적화

문제 해결

오류: 'Reasoning mode is enabled but model does not support reasoning'

원인: reasoning_effort 파라미터가 null이 아닌 값으로 설정되었지만 지정된 model_type에서 추론을 지원하지 않습니다.

해결 방법:

- 모델 유형이 amazon.nova-2-lite-v1:0:256k인지 확인
- 다른 모델을 사용하는 경우 추론 가능 모델로 전환하거나 레시피에서 reasoning_effort 파라미터를 제거합니다.

평가 작업 시작

다음은 제안된 평가 인스턴스 유형 및 모델 유형 구성을 제공합니다.

```
# 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]
```

또한 Amazon EKS 클러스터 콘솔을 통해 작업 상태를 볼 수 있어야 합니다.

평가 결과 액세스 및 분석

평가 작업이 성공적으로 완료되면 이 섹션의 정보를 사용하여 결과를 액세스하고 분석할 수 있습니다. 레시피에 정의된 `output_s3_path`(예: `s3://output_path/`)를 기반으로 출력 구조는 다음과 같습니다.

```
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]
```

지표 결과는 지정된 다음 S3 출력 위치에 저장됩니다. `s3://output_path/job_name/eval-result/result-timestamp.json`.

Tensorboard 결과는 S3 경로에 저장됩니다. `s3://output_path/job_name/eval-tensorboard-result/eval/event.out.tfevents.epoch+ip`.

`llm_judge` 및 `strong_reject`를 제외한 모든 추론 출력은 다음 S3 경로에 저장됩니다. `s3://output_path/job_name/eval-result/details/model/taskname.parquet`.

`gen_qa`의 경우 `inference_output.jsonl` 파일에는 각 JSON 객체에 대해 다음 필드가 포함됩니다.

- `prompt` - 모델에 제출된 최종 프롬프트
- `inference` - 모델의 원시 추론 출력
- `gold` - 입력 데이터세트의 대상 응답
- `metadata` - 제공된 경우 입력 데이터세트의 메타데이터 문자열

Tensorboard에서 평가 지표를 시각화하려면 다음 단계를 완료하세요.

1. SageMaker AI Tensorboard로 이동합니다.
2. S3 폴더를 선택합니다.
3. S3 폴더 경로를 추가합니다. 예: `s3://output_path/job-name/eval-tensorboard-result/eval`
4. 동기화가 완료될 때까지 기다립니다.

시계열, 스칼라 및 텍스트 시각화를 사용할 수 있습니다.

다음 모범 사례를 따르는 것이 좋습니다.

- 출력 경로를 모델 및 벤치마크 유형별로 정리하여 유지합니다.
- 쉽게 추적할 수 있도록 일관된 이름 지정 규칙을 유지합니다.
- 추출된 결과를 안전한 위치에 저장합니다.
- TensorBoard 동기화 상태를 모니터링하여 데이터가 성공적으로 로드되었는지 확인합니다.

SageMaker HyperPod 작업 오류 로그는 CloudWatch 로그 그룹 `/aws/sagemaker/Clusters/cluster-id`에서 찾을 수 있습니다.

로그 확률 출력 형식

`top_logprobs`가 추론 설정에서 구성된 경우 평가 출력에는 parquet 파일에 토큰 수준 로그 확률이 포함됩니다. 각 토큰 위치에는 로그 확률이 다음과 같이 구성된 상위 후보 토큰의 사전이 포함되어 있습니다.

```
{
  "Ġint": {"logprob_value": -17.8125, "decoded_value": " int"},
  "Ġthe": {"logprob_value": -2.345, "decoded_value": " the"}
}
```

각 토큰 항목에는 다음이 포함됩니다.

- `logprob_value`: 토큰의 로그 확률 값
- `decoded_value`: 사람이 읽을 수 있는 디코딩된 토큰 문자열 표현

원시 토큰화 토큰은 고유성을 보장하기 위한 사전 키로 사용되는 반면, `decoded_value`는 사람이 읽을 수 있는 해석을 제공합니다.

RFT 평가

Note

자체 AWS 환경에서 원격 보상 함수를 통한 평가는 Amazon Nova Forge 고객인 경우에만 사용할 수 있습니다.

Important

`rl_env` 구성 필드는 훈련이 아닌 평가에만 사용됩니다. 훈련 중에 `reward_lambda_arn`(싱글턴)을 사용하여 보상 함수를 구성하거나 `rollout.delegate: true`(멀티턴)를 사용하여 BYOO 인프라를 구성합니다.

RFT 평가란 무엇인가요?

RFT 평가를 사용하면 강화 학습 훈련 이전, 도중 또는 이후에 사용자 지정 보상 함수를 통해 모델의 성능을 평가할 수 있습니다. 사전 정의된 지표를 사용하는 표준 평가와 달리, RFT 평가를 사용하면 특정 요구 사항에 따라 모델 출력의 점수를 계산하는 Lambda 함수를 통해 고유한 성공 기준을 정의할 수 있습니다.

RFT로 평가하는 이유는 무엇인가요?

RL 미세 조정 프로세스에서 다음을 지원하는지 확인하려면 평가가 중요합니다.

- 특정 사용 사례 및 인적 값에 맞게 모델 정렬 개선
- 주요 태스크에 대한 모델 기능 유지 관리 또는 개선
- 다른 태스크에서 사실성 감소, 세부성 증가 또는 성능 저하와 같은 의도하지 않은 부작용 방지
- 보상 함수에 정의된 대로 사용자 지정 성공 기준 충족

RFT 평가를 사용해야 하는 경우

다음 시나리오에서 RFT 평가를 사용합니다.

- RFT 훈련 이전: 평가 데이터세트에서 기준 지표 설정
- RFT 훈련 도중: 중간 체크포인트를 사용하여 훈련 진행 상황 모니터링
- RFT 훈련 이후: 최종 모델이 요구 사항을 충족하는지 검증
- 모델 비교: 일관된 보상 기준을 사용하여 여러 모델 버전 평가

Note

사용자 지정 도메인별 지표가 필요한 경우 RFT 평가를 사용합니다. 범용 평가(정확성, 복잡성, BLEU)의 경우 표준 평가 방법을 사용합니다.

주제

- [데이터 형식 요구 사항](#)
- [평가 레시피 준비](#)
- [보상 함수 사전 설정](#)
- [보상 함수 생성](#)
- [IAM 권한](#)

- [평가 작업 실행](#)
- [평가 결과 이해](#)

데이터 형식 요구 사항

입력 데이터 구조

RFT 평가 입력 데이터는 OpenAI 강화 미세 조정 형식을 따라야 합니다. 각 예제는 다음을 포함하는 JSON 객체입니다.

- `messages`: `system` 및 `user` 역할을 포함하는 대화 턴 배열
- 기타 선택적 메타데이터(예: `reference_answer`)

데이터 형식 예제

다음 예제에서는 필수 형식을 보여줍니다.

```
{
  "messages": [
    {
      "role": "user",
      "content": [
        {
          "type": "text",
          "text": "Solve for x. Return only JSON like {\"x\": <number>}. Equation: 2x + 5 = 13"
        }
      ]
    }
  ],
  "reference_answer": {
    "x": 4
  }
}
```

현재 제한 사항

다음 제한 사항은 RFT 평가에 적용됩니다.

- 텍스트만 해당: 멀티모달 입력(이미지, 오디오, 비디오)은 지원되지 않음
- 싱글턴 대화: 단일 사용자 메시지만 지원(멀티턴 대화 없음)

- JSON 형식: 입력 데이터는 JSONL 형식이어야 함(줄당 JSON 객체 1개)
- 모델 출력: 지정된 모델에서 생성된 완료를 대상으로 평가가 수행됨

평가 레시피 준비

샘플 레시피 구성

다음 예제에서는 전체 RFT 평가 레시피를 보여줍니다.

```
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>
```

보상 함수 사전 설정

RFT Lambda 함수에 쉽게 통합할 수 있도록 두 가지 사전 설정 보상 함수(prime_code 및 prime_math)를 Lambda 계층으로 사용할 수 있습니다.

개요

이러한 사전 설정 함수는 다음에 대한 즉각적인 평가 기능을 제공합니다.

- prime_code: 코드 생성 및 정확성 평가
- prime_math: 수학적 추론 및 문제 해결 평가

빠른 설정

사전 설정된 보상 함수를 사용하는 방법:

1. [nova-custom-eval-sdk 릴리스](#)에서 Lambda 계층 다운로드
2. AWS CLI를 사용하여 Lambda 계층 게시:

```
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. AWS Console에서 Lambda 함수에 계층 추가(사용자 지정 계층에서 preset-function-layer를 선택하고 numpy 종속성에서 AWSSDKPandas-Python312도 추가)
4. Lambda 코드에서 다음을 가져와 사용하세요.

```
from prime_code import compute_score # For code evaluation
from prime_math import compute_score # For math evaluation
```

prime_code 함수

용도: 테스트 사례를 기준으로 코드를 실행하고 정확성을 측정하여 Python 코드 생성 작업을 평가합니다.

평가의 입력 데이터세트 형식 예제:

```
{
  "messages": [
    {
      "role": "user",
      "content": "Write a function that returns the sum of two numbers."
    },
    {
      "role": "assistant",
      "content": "def sum(a, b): return a + b"
    }
  ],
  "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."
    },
    {
      "role": "assistant",
      "content": "def is_even(n): return n % 2 == 0"
    }
  ],
  "reference_answer": {
    "inputs": ["4", "7", "0", "-2"],
    "outputs": ["True", "False", "True", "True"]
  }
}
```

주요 기능:

- 마크다운 코드 블록에서 자동 코드 추출
- 함수 탐지 및 직접 호출 기반 테스트
- 제한 시간 보호를 사용하는 테스트 사례 실행
- 구문 검증 및 컴파일 검사
- 트레이스백을 사용하는 세부 오류 보고

prime_math 함수

용도: 기호 수학 지원을 통해 수학 추론 및 문제 해결 기능을 평가합니다.

입력 형식:

```
{
  "messages": [
    {
      "role": "user",
      "content": "What is the derivative of x^2 + 3x?."
    },
    {
      "role": "assistant",
      "content": "2*x + 3"
    }
  ],
  "reference_answer": "2*x + 3"
}
```

주요 기능:

- SymPy를 사용하는 기호 수학 평가
- 여러 응답 형식(LaTeX, 일반 텍스트, 기호)
- 수학적 동등성 검사
- 표현식 정규화 및 단순화

모범 사례

사전 설정된 보상 함수를 사용할 때 다음 모범 사례를 따릅니다.

- 테스트 사례에서 적절한 데이터 유형 사용(정수 대 문자열, 부울 대 'True')
- 코드 문제에서 명확한 함수 서명 제공

- 테스트 입력에서 엡지 케이스 포함(0, 음수, 빈 입력)
- 참조 답변에서 일관된 수학 표현식 형식 지정
- 배포 전에 샘플 데이터를 사용하여 보상 함수 테스트

보상 함수 생성

Lambda ARN

Lambda ARN에 대해 다음 형식을 참조해야 합니다.

```
"arn:aws:lambda:*:*:function:*SageMaker*"
```

Lambda에 이 이름 지정 스키마가 없는 경우 이 오류가 발생하며 작업이 실패합니다.

```
[ERROR] Unexpected error: lambda_arn must contain one of: ['SageMaker', 'sagemaker', 'Sagemaker'] when running on SMHP platform (Key: lambda_arn)
```

Lambda 함수 구조

Lambda 함수는 모델 출력 배치를 수신하고 보상 점수를 반환합니다. 다음은 샘플 구현입니다.

```
from typing import List, Any
import json
import re
from dataclasses import asdict, dataclass

@dataclass
class MetricResult:
    """Individual metric result."""
    name: str
    value: float
    type: str

@dataclass
class RewardOutput:
    """Reward service output."""
    id: str
    aggregate_reward_score: float
    metrics_list: List[MetricResult]
```

```
def lambda_handler(event, context):
    """ Main lambda handler """
    return lambda_grader(event)

def lambda_grader(samples: list[dict]) -> list[dict]:
    """ Core grader function """
    scores: List[RewardOutput] = []

    for sample in samples:
        print("Sample: ", json.dumps(sample, indent=2))

        # Extract components
        idx = sample.get("id", "no id")
        if not idx or idx == "no id":
            print(f"ID is None/empty for sample: {sample}")

        ground_truth = sample.get("reference_answer")

        if "messages" not in sample:
            print(f"Messages is None/empty for id: {idx}")
            continue

        if ground_truth is None:
            print(f"No answer found in ground truth for id: {idx}")
            continue

        # Get model's response (last turn is assistant turn)
        last_message = sample["messages"][-1]

        if last_message["role"] != "nova_assistant":
            print(f>Last message is not from assistant for id: {idx}")
            continue

        if "content" not in last_message:
            print(f"Completion text is empty for id: {idx}")
            continue

        model_text = last_message["content"]

        # --- Actual scoring logic (lexical overlap) ---
        ground_truth_text = _extract_ground_truth_text(ground_truth)
```

```

# Calculate main score and individual metrics
overlap_score = _lexical_overlap_score(model_text, ground_truth_text)

# Create two separate metrics as in the first implementation
accuracy_score = overlap_score # Use overlap as accuracy
fluency_score = _calculate_fluency(model_text) # New function for fluency

# Create individual metrics
metrics_list = [
    MetricResult(name="accuracy", value=accuracy_score, type="Metric"),
    MetricResult(name="fluency", value=fluency_score, type="Reward")
]

ro = RewardOutput(
    id=idx,
    aggregate_reward_score=overlap_score,
    metrics_list=metrics_list
)

print(f"Response for id: {idx} is {ro}")
scores.append(ro)

# Convert to dict format
result = []
for score in scores:
    result.append({
        "id": score.id,
        "aggregate_reward_score": score.aggregate_reward_score,
        "metrics_list": [asdict(metric) for metric in score.metrics_list]
    })

return result

def _extract_ground_truth_text(ground_truth: Any) -> str:
    """
    Turn the `ground_truth` field into a plain string.
    """
    if isinstance(ground_truth, str):
        return ground_truth

    if isinstance(ground_truth, dict):
        # Common patterns: { "explanation": "...", "answer": "..." }

```

```

        if "explanation" in ground_truth and isinstance(ground_truth["explanation"],
str):
            return ground_truth["explanation"]
        if "answer" in ground_truth and isinstance(ground_truth["answer"], str):
            return ground_truth["answer"]
        # Fallback: stringify the whole dict
        return json.dumps(ground_truth, ensure_ascii=False)

# Fallback: stringify anything else
return str(ground_truth)

def _tokenize(text: str) -> List[str]:
    # Very simple tokenizer: lowercase + alphanumeric word chunks
    return re.findall(r"\w+", text.lower())

def _lexical_overlap_score(model_text: str, ground_truth_text: str) -> float:
    """
    Simple lexical overlap score in [0, 1]:
        score = |tokens(model) ∩ tokens(gt)| / |tokens(gt)|
    """
    gt_tokens = _tokenize(ground_truth_text)
    model_tokens = _tokenize(model_text)

    if not gt_tokens:
        return 0.0

    gt_set = set(gt_tokens)
    model_set = set(model_tokens)
    common = gt_set & model_set

    return len(common) / len(gt_set)

def _calculate_fluency(text: str) -> float:
    """
    Calculate a simple fluency score based on:
    - Average word length
    - Text length
    - Sentence structure

    Returns a score between 0 and 1.
    """

```

```
# Simple implementation - could be enhanced with more sophisticated NLP
words = _tokenize(text)

if not words:
    return 0.0

# Average word length normalized to [0,1] range
# Assumption: average English word is ~5 chars, so normalize around that
avg_word_len = sum(len(word) for word in words) / len(words)
word_len_score = min(avg_word_len / 10, 1.0)

# Text length score - favor reasonable length responses
ideal_length = 100 # words
length_score = min(len(words) / ideal_length, 1.0)

# Simple sentence structure check (periods, question marks, etc.)
sentence_count = len(re.findall(r'[.!?]+', text)) + 1
sentence_ratio = min(sentence_count / (len(words) / 15), 1.0)

# Combine scores
fluency_score = (word_len_score + length_score + sentence_ratio) / 3

return fluency_score
```

Lambda 요청 형식

Lambda 함수는 다음 형식으로 데이터를 수신합니다.

```
[
  {
    "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

메시지 구조에는 입력 데이터 형식과 일치하는 중첩된 content 배열이 포함됩니다.
nova_assistant 역할이 있는 마지막 메시지에는 모델의 생성된 응답이 포함됩니다.

Lambda 응답 형식

Lambda 함수는 다음 형식으로 데이터를 반환해야 합니다.

```

[
  {
    "id": "sample-001",
    "aggregate_reward_score": 0.75,
    "metrics_list": [
      {
        "name": "accuracy",
        "value": 0.85,
        "type": "Metric"
      },
      {
        "name": "fluency",
        "value": 0.90,

```

```

        "type": "Reward"
    }
]
}
]
```

응답 필드:

- id: 입력 샘플 ID와 일치해야 함
- aggregate_reward_score: 전체 점수(일반적으로 0.0~1.0)
- metrics_list: 다음을 포함하는 개별 지표의 배열:
 - name: 지표 식별자(예: 'accuracy', 'fluency')
 - value: 지표 점수(일반적으로 0.0~1.0)
 - type: 'Metric'(보고용) 또는 'Reward'(훈련에 사용됨)

IAM 권한

필수 권한

SageMaker AI 실행 역할에는 Lambda 함수를 간접 호출할 권한이 있어야 합니다. SageMaker AI 실행 역할에 이 정책을 추가합니다.

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "lambda:InvokeFunction"
      ],
      "Resource": "arn:aws:lambda:region:account-id:function:function-name"
    }
  ]
}
```

Lambda 실행 역할

Lambda 함수의 실행 역할에는 기본 Lambda 실행 권한이 필요합니다.

```
{
```

```

"Version": "2012-10-17",
"Statement": [
  {
    "Effect": "Allow",
    "Action": [
      "logs:CreateLogGroup",
      "logs:CreateLogStream",
      "logs:PutLogEvents"
    ],
    "Resource": "arn:aws:logs:*:*:*"
  }
]
}

```

추가 권한: Lambda 함수가 다른 AWS 서비스(예: 참조 데이터의 경우 Amazon S3, 로깅의 경우 DynamoDB)에 액세스하는 경우 해당 권한을 Lambda 실행 역할에 추가합니다.

평가 작업 실행

1. 데이터 준비

- 데이터 형식 요구 사항에 따라 평가 데이터 형식 지정
- Amazon S3에 JSON 파일(s3://your-bucket/eval-data/eval_data.jsonl) 업로드

2. 레시피 구성

사용자 구성으로 샘플 레시피를 업데이트합니다.

- model_name_or_path를 모델 위치로 설정
- lambda_arn을 보상 함수 ARN으로 설정
- output_s3_path를 원하는 출력 위치로 설정
- 필요에 따라 inference 파라미터 조정

레시피를 rft_eval_recipe.yaml로 저장

3. 평가 실행

제공된 노트북을 사용하여 평가 작업 실행: [Nova 모델 평가 노트북](#)

4. 진행 상황 모니터링

다음은 통해 평가 작업을 모니터링합니다.

- SageMaker AI 콘솔: 작업 상태 및 로그 확인
- CloudWatch Logs: 세부 실행 로그 보기
- Lambda 로그: 보상 함수 문제 디버깅

평가 결과 이해

출력 형식

평가 작업은 결과를 지정된 Amazon S3 위치에 JSONL 형식으로 출력합니다. 각 줄에는 하나의 샘플에 대한 평가 결과가 포함됩니다.

```
{
  "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

RFT 평가 작업 출력은 Lambda 응답 형식과 동일합니다. 평가 서비스는 Lambda 함수의 응답을 수정하지 않고 전달하여 보상 계산과 최종 결과 사이의 일관성을 보장합니다.

결과 해석

보상 점수 집계:

- 범위: 일반적으로 0.0(최저)~1.0(최상)이지만 구현에 따라 다름

- 용도: 전체 성능을 요약하는 단일 숫자
- 사용법: 모델 비교, 훈련 대비 개선 추적

개별 지표:

- 지표 유형: 분석을 위한 정보용 지표
- 보상 유형: RFT 훈련 도중 사용되는 지표
- 해석: 반대 지표를 설계하지 않는 한, 값이 높을수록 일반적으로 더 나은 성능을 나타냄

성능 벤치마크

'양호'한 성능을 구성하는 요소는 사용 사례에 따라 달라집니다.

점수 범위	해석	작업
0.8 - 1.0	우수	배포 준비된 모델
0.6~0.8	양호	약간의 개선이 도움이 될 수 있음
0.4~0.6	공정	상당한 개선이 필요함
0.0~0.4	열악	훈련 데이터 및 보상 함수 검토

Important

다음은 일반적인 지침입니다. 비즈니스 요구 사항, 기존 모델 성능, 도메인별 제약 조건 및 추가 훈련의 비용 편익 분석을 기반으로 자체 임계치를 정의합니다.

MLflow를 사용하여 HyperPod 작업 모니터링

MLflow를 사용하여 SageMaker HyperPod에서 훈련 작업을 추적 및 모니터링할 수 있습니다. 다음 단계에 따라 MLflow를 설정하고 훈련 레시피에 연결합니다.

MLflow 앱 생성

AWS CLI 명령 예제

```
aws sagemaker-mlflow create-mlflow-app \
  --name <app-name> \
  --artifact-store-uri <s3-bucket-name> \
  --role-arn <role-arn> \
  --region <region-name>
```

출력 예시

```
{
  "Arn": "arn:aws:sagemaker:us-east-1:111122223333:mlflow-app/app-LGZE0Z2UY4NZ"
}
```

미리 서명된 URL 생성

AWS CLI 명령 예제

```
aws sagemaker-mlflow create-presigned-mlflow-app-url \
  --arn <app-arn> \
  --region <region-name> \
  --output text
```

출력 예시


```
https://app-LGZE0Z2UY4NZ.mlflow.sagemaker.us-east-1.app.aws/auth?
authToken=eyJhbGciOiJIUzI1NiJ9.eyJhdXRoVG9rZW5JZCI6IkxETVBPUyIsImZhc0NyZWRLbnRpYWxzIjoiQWdWNGhD
```

미리 서명된 URL을 열고 앱 보기

다시 시도하려면

```
https://app-LGZE0Z2UY4NZ.mlflow.sagemaker.us-east-1.app.aws/auth?
authToken=eyJhbGciOiJIUzI1NiJ9.eyJhdXRoVG9rZW5JZCI6IkxETVBPUyIsImZhc0NyZWRLbnRpYWxzIjoiQWdWNGhD
```

보기




SageMaker HyperPod 레시피의 실행 블록에서 레시피로 전달

방법

```
run
    mlflow_tracking_uri: arn:aws:sagemaker:us-east-1:111122223333:mlflow-app/app-
    LGZE0Z2UY4NZ
```

보기



반복 훈련

개요

반복 훈련은 여러 훈련 방법(훈련, 평가, 오류 분석, 데이터/목표/하이퍼파라미터 조정 등)에서 여러 훈련 주기를 통해 모델을 반복적으로 미세 조정하는 프로세스로, 각 라운드는 이전 체크포인트에서 시작됩니다. 이 접근 방식을 사용하면 모델 실패 모드를 체계적으로 목표로 지정하고, 특정 약점을 해결하는 선별된 예제를 통합하며, 시간이 지남에 따라 변화하는 요구 사항에 적응할 수 있습니다.

단일 패스 훈련의 이점:

- 목표 개선: 평가를 통해 발견한 특정 실패 패턴 해결
- 적응형 개선: 배포 전환 또는 진화하는 제품 요구 사항에 대응

- 위험 완화: 긴 단일 훈련 실행에 커밋하지 않고 점진적으로 개선 사항 검증
- 데이터 효율성: 모델 성능이 낮은 영역에 데이터 수집 노력 집중
- 커리큘럼 훈련: 점점 더 높은 품질의 데이터를 사용하는 여러 라운드로 구성된 훈련

작동 방식

체크포인트 위치 및 액세스

각 훈련 작업이 완료되면 훈련 구성의 `output_path` 파라미터로 지정된 출력 위치에 매니페스트 파일이 생성됩니다.

체크포인트에 액세스하는 방법

- S3에서 지정된 `output_path`로 이동
- `output.tar.gz` 파일을 다운로드하고 압축 풀기
- 내부에서 `manifest.json` 파일 열기
- 훈련된 모델의 S3 URI를 포함하는 `checkpoint_s3_bucket` 파라미터 찾기

manifest.json 구조 예제

```
{
  "checkpoint_s3_bucket": "s3://customer-escrow-<account-number>-smtj-<unique-identifier>/<job-name>/stepID",
  ...
}
```

에스크로 버킷 이해

Amazon Nova 가중치는 독점 데이터이므로 훈련된 모델 체크포인트는 계정에 복사되지 않고 AWS 관리형 계정 내 에스크로 S3 버킷에 저장됩니다. 다음은 이러한 에스크로 버킷의 특징입니다.

- 사용자 지정된 모델 가중치를 안전하게 포함함
- 다른 AWS 서비스(추론, 평가 및 후속 훈련 작업)에서 참조할 수 있음
- IAM 권한을 통해 AWS 계정에만 액세스할 수 있음
- 계정에서 표준 S3 스토리지 요금 발생(비용 고려 사항 참조)

다음 훈련 실행에서 에스스로 버킷 경로를 `model_name_or_path`로 사용하여 반복 훈련을 계속할 수 있습니다.

반복 훈련에 체크포인트 사용

이전 체크포인트를 기본 모델로 사용하도록 다음 훈련 작업을 구성합니다.

```
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
```

반복 훈련을 사용해야 하는 경우

이상적인 사용 사례

다음과 같은 경우에 반복 훈련을 사용합니다.

- 피드백 루프 - 실제 실패 사례를 수집하고 체계적으로 해결하는 기능
- 동적 환경 - 주기적 모델 업데이트가 필요한 문서, API 또는 지원 주제 개선
- 강력한 평가 - 개선 사항을 신뢰할 수 있는 방식으로 측정하기 위한 강력한 벤치마크 및 평가 프레임워크(아래 예제 참조)
- ML 운영 기능 - 여러 훈련 주기 및 버전 제어를 관리하는 리소스

강력한 평가 프레임워크 예제

- 통과/실패 임계치가 있는 자동화된 벤치마크 모음
- 평가자 간 신뢰성 지표를 포함하는 인적 평가 프로토콜
- 엣지 사례 및 적대적 입력을 다루는 레드 팀 테스트 시나리오
- 프로덕션 영향을 측정하기 위한 A/B 테스트 인프라

일반적인 패턴

SFT → RFT 파이프라인: 자주 사용되는 반복 패턴에는 다음이 포함됩니다.

- SFT 우선 - 데모 예제를 통해 문제를 해결하는 방법을 모델에 가르침
- RFT 보조 - 보상 신호를 사용하여 광범위한 문제 공간에서 성능 최적화

이 시퀀스는 처음에 모델의 성능이 낮은 경우에 필수적입니다. 정확도가 거의 0에 가까운 모델의 경우 먼저 SFT를 통해 기본적인 문제 해결 기능을 설정하지 않으면 RFT로 성능이 개선되지 않습니다.

반복 훈련을 사용하지 않는 경우

다음 경우에는 반복 훈련을 피합니다.

- 안정적이고 잘 정의된 태스크 - 일관된 요구 사항이 이미 성능 상한에 가까운 고정 데이터
- 간단한 분류 문제 - 단일 패스 훈련으로 충분한 좁은 범위의 태스크
- 리소스 제약 - 여러 훈련 주기를 관리하기 위한 전용 ML 운영 기능 부족
- 마진 게인 - 오버헤드로 최소 성능 개선 사항이 정당화되지 않는 경우

워크플로 예제: SFT → RFT

이 예제에서는 추론 모델에 대한 일반적인 반복 훈련 패턴을 보여줍니다.

1단계: 초기 SFT 훈련

데이터셋을 사용하여 SFT 훈련 작업을 구성하고 시작합니다.

```
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
```

근거: SFT는 모델 출력을 원하는 형식과 음성으로 형성하여 기본 기능을 설정하는 추가 데모를 제공합니다.

훈련이 완료된 후

- 훈련 작업에 구성된 `output_path` 기록
- 해당 위치에서 `output.tar.gz` 다운로드

- manifest.json 추출 및 찾기
- checkpoint_s3_bucket 값 복사

2단계: SFT 체크포인트에서 RFT 훈련

SFT 체크포인트를 사용하여 새 RFT 훈련 작업을 생성합니다.

```
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>
```

근거: RFT 훈련은 SFT 파운데이션을 기반으로 구축되므로 모델은 보상 함수에 의해 최적화된 보다 복잡한 추론 패턴을 개발할 수 있습니다.

3단계: 평가 및 반복

RFT 체크포인트에서 평가를 실행하여 성능을 평가합니다.

```
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
```

목표 지표가 충족되지 않으면 조정된 데이터 또는 하이퍼파라미터로 계속 반복합니다.

Important

훈련 기법(LoRA 및 전체 순위)은 모든 반복에서 일관성을 유지해야 합니다.

- SFT를 LoRA와 함께 사용하는 경우 RFT를 LoRA와 함께 사용해야 함
- SFT를 전체 순위와 함께 사용하는 경우 RFT를 전체 순위와 함께 사용해야 함
- LoRA 및 전체 순위 중간 파이프라인 사이를 전환할 수 없습니다.

Important

Amazon에서 소유한 출력 S3 버킷에서 암호화에 KMS 키를 사용하는 경우 향후 모든 반복에 동일한 KMS 키를 사용해야 합니다.

여러 반복에서 진행 상황 모니터링

작업에 대한 [MLflow를 설정](#)하여 MLflow를 통해 지표를 추적할 수 있습니다.

MLflow 앱 생성

Studio UI 사용: Studio UI를 통해 훈련 작업을 생성하는 경우 기본 MLflow 앱이 자동으로 생성되고 고급 옵션에서 기본적으로 선택됩니다.

CLI 사용: CLI를 사용하는 경우 MLflow 앱을 생성하고 이를 훈련 작업 API 요청에 대한 입력으로 전달해야 합니다.

```
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)
```

MLflow 앱에 액세스

CLI 사용: 미리 서명된 URL을 생성하여 MLflow 앱 UI에 액세스합니다.

```
aws sagemaker create-presigned-mlflow-app-url \
  --arn $mlflow_app_arn \
  --region $region \
  --output text
```

Studio UI 사용: Studio UI는 MLflow에 저장된 주요 지표를 표시하고 MLflow 앱 UI에 대한 링크를 제공합니다.

추적할 주요 지표

여러 반복에서 이러한 지표를 모니터링하여 개선 사항을 평가하고 작업 진행 상황을 추적합니다.

SFT의 경우

- 훈련 손실 곡선
- 소비된 샘플 수 및 샘플 처리 시간
- 홀드아웃 테스트 세트의 성능 정확도
- 형식 규정 준수(예: 유효한 JSON 출력 비율)
- 도메인별 평가 데이터의 퍼플렉시티

RFT의 경우

- 훈련 대비 평균 보상 점수
- 보상 분포(높은 보상 응답의 백분율)
- 검증 보상 추세(과적합 감시)
- 태스크별 성공률(예: 코드 실행 통과 비율, 수학 문제 정확도)

일반

- 반복 간 벤치마크 성능 델타
- 대표 샘플에 대한 인적 평가 점수
- 프로덕션 지표(반복적으로 배포하는 경우)

중지 시점 결정

다음과 같은 경우 반복을 중지합니다.

- 성능 정체 - 추가 훈련으로도 대상 지표가 더 이상 유의미하게 개선되지 않음
- 기법 전환 지원 - 한 기법이 정체된 경우 성능 상한을 깨뜨리려면 전환(예: SFT → RFT → SFT) 시도
- 목표 지표 달성 - 성공 기준을 충족함
- 회귀 감지 - 새 반복은 성능을 저하시킴(아래 롤백 절차 참조)

자세한 평가 절차는 평가 섹션을 참조하세요.

모범 사례

소규모로 시작하여 점진적으로 확장

스케일 업하기 전에 최소 데이터세트와 단일 훈련 에포크로 시작하여 접근 방식을 검증합니다. 그러면 신뢰가 구축되고 문제를 조기에 식별하는 데 도움이 됩니다.

명확한 성공 지표 설정

시작하기 전에 다음과 같이 정량적 및 정성적 지표를 정의합니다.

사용 사례별 성공 지표 예제

- 질문 답변 - 정확한 일치 정확도, F1 점수, 인적 선호도 등급
- 코드 생성 - 유닛 테스트 통과 비율, 컴파일 성공, 실행 시간
- 추론 태스크 - 단계 정확도, 최종 답변 정확성, 보상 점수
- 콘텐츠 생성 - 일관성 점수, 실제 정확도, 스타일 준수

자동화된 평가 구현

자동화된 평가 파이프라인을 설정하여 각 라운드 후 성능을 추적하여 빠른 반복 및 목표 비교를 지원합니다.

엄격한 버전 제어 유지 관리

각 반복에 대해 문서화합니다.

- 데이터세트 버전 및 수정 사항
- 모델 체크포인트 위치
- 하이퍼파라미터 변경 사항
- 성능 지표 및 델타
- 정성적 관찰

그러면 하면 규격화된 지식이 구축되고 디버깅을 지원합니다.

수량보다 데이터 품질에 집중

단순히 데이터세트 크기를 늘리는 대신, 이전 라운드의 실패 사례를 분석하고 목표에 맞는 고품질 예제를 추가합니다.

반복 예산 계획

일반적인 범위로 3~5회 반복을 계획합니다.

- 1~2회 반복 - 종종 단순한 개선 또는 최종 다듬기 작업에 충분함
- 3~5회 반복 - 여러 개선 주기가 필요한 복잡한 태스크에 적합함
- 5회 이상의 반복 - 반복 감소를 나타내거나 여러 접근 방식에 필요할 수 있음

컴퓨팅 예산 및 성능 개선률에 따라 조정합니다.

롤백 기능 구현

반복 시 회귀가 발생하는 경우:

- 회귀 식별 - 체크포인트 간 평가 지표 비교
- 이전 체크포인트로 돌아가기 - 이전 체크포인트의 S3 경로를 `model_name_or_path`로 사용
- 훈련 접근 방식 조정 - 재시도 전에 데이터, 하이퍼파라미터 또는 기법 수정
- 실패 사례 문서화 - 똑같은 상황을 방지하기 위해 회귀의 원인 기록

롤백 예제

```
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>"
```

비용 고려 사항

체크포인트 저장

- 위치 - 에스크로 버킷에 저장된 체크포인트에서는 AWS 계정에 청구되는 표준 S3 스토리지 요금이 발생함
- 보존 - 명시적으로 삭제되지 않는 한 체크포인트는 무기한 보존됨
- 관리 - 수명 주기 정책을 구현하여 더 이상 필요하지 않은 오래된 체크포인트를 아카이브하거나 삭제함

비용 최적화 팁

- 최신 반복을 검증한 후 중간 체크포인트 삭제
- 더 저렴한 비용으로 장기 보존을 위해 S3 Glacier에 체크포인트 아카이브
- 규정 준수 및 실험 요구 사항에 따라 보존 정책 설정

제한 사항

모델 패밀리 일관성

반복적으로 훈련하는 경우 모든 반복에서 동일한 모델 유형을 사용해야 합니다.

초기 훈련

```
run:
  model_type: amazon.nova-2-lite-v1:0:256k
  model_name_or_path: "nova-lite-2/prod"
```

후속 반복에서는 동일한 `model_type`을 사용해야 함

```
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>"
```

훈련 기법의 일관성

훈련 기법은 여러 반복에서 일관성을 유지해야 합니다.

- LoRA 훈련 모델은 LoRA로만 반복 훈련할 수 있습니다.
- 전체 순위 훈련 모델은 전체 순위로만 반복 훈련할 수 있습니다.

반복 훈련에서 LoRA 어댑터의 작동 방식

- 각 LoRA 훈련 반복은 새 어댑터 가중치를 생성함
- 새 어댑터는 이전 어댑터를 대체함(스택되지 않음)
- 기본 모델은 동결된 상태로 유지되며, 어댑터만 업데이트됨

기법 호환성 매트릭스

초기 훈련	반복을 지원하는 방법
SFT(전체 순위)	SFT(전체 순위), RFT(전체 순위)
SFT(LoRA)	SFT(LoRA), RFT(LoRA)
RFT(전체 순위)	RFT(전체 순위)
RFT(LoRA)	RFT(LoRA)

작업 시작 전에 호환성 확인

- 이전 훈련 레시피를 확인하여 모델 유형 및 훈련 기법(LoRA 및 전체 순위) 식별
- 새 레시피에서 모델 유형과 기법이 모두 일치하는지 확인
- manifest.json을 검토하여 체크포인트 경로가 올바른지 확인

문제 해결

오류: 'Incompatible model training techniques detected'

원인: 훈련 기법(LoRA 및 전체 순위)이 체크포인트의 기법과 일치하지 않습니다.

해결 방법: 레시피가 원래 모델과 동일한 훈련 기법을 사용하는지 확인합니다.

- 체크포인트가 LoRA로 훈련된 경우 새 레시피에서 LoRA 사용
- 체크포인트가 전체 순위로 훈련된 경우 새 레시피에서 전체 순위 사용

오류: 'Base model for the job extracted from model_name_or_path does not match model_type'

원인: model_type에 지정된 모델 유형이 체크포인트의 실제 모델과 일치하지 않습니다.

해결 방법: 다음을 확인합니다.

- 레시피에서 model_type이 원래 모델 유형과 일치함

- model_name_or_path에서 체크포인트 S3 경로가 올바름
- 올바른 manifest.json 파일의 경로를 사용하고 있음

올바른 구성 예제

```
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>"
```

오류: 'Model configuration not found'

원인: model_name_or_path의 S3 경로가 유효하지 않거나 이에 액세스할 수 없습니다.

해결 방법:

- S3 경로가 manifest.json 파일에서 올바르게 복사되었는지 확인
- 에스크로 버킷에 액세스할 수 있는 권한이 IAM 역할에 있는지 확인
- 이전 훈련 작업이 성공적으로 완료되었는지 확인
- 경로에 오타가 있는지 확인

반복 후 성능 회귀

증상: 새 훈련 반복 후 평가 지표가 감소합니다.

해결 방법:

- 롤백 - 이전 체크포인트를 기본 모델로 사용
- 분석 - 실패한 반복에 대한 훈련 로그 및 데이터 품질 검토
- 조정 - 하이퍼파라미터 수정(학습 속도 감소), 데이터 품질 향상 또는 훈련 에포크 감소
- 재시도 - 조정을 통해 새 반복 시작

SageMaker 추론

이제 SageMaker 추론에서 사용자 지정 Amazon Nova 모델을 사용할 수 있습니다. SageMaker에서 Amazon Nova를 사용하면 훈련된 사용자 지정 Amazon Nova 모델에서 예측 또는 추론을 가져올 수 있습니다. SageMaker는 모든 ML 추론 요구 사항을 충족하는 데 도움이 되는 다양한 ML 인프라 및 모델

배포 옵션을 제공합니다. SageMaker 추론을 사용하면 모델 배포를 확장하고, 프로덕션에서 모델을 더 효과적으로 관리하며, 운영 부담을 줄일 수 있습니다.

SageMaker는 지연 시간이 짧은 추론을 위한 실시간 엔드포인트 및 요청 배치 처리를 위한 비동기 엔드포인트와 같은 다양한 추론 옵션을 제공합니다. 사용 사례에 적합한 추론 옵션을 활용하면 효율적인 모델 배포 및 추론을 보장할 수 있습니다. SageMaker 추론에 대한 자세한 내용은 [Deploy models for inference](#)를 참조하세요.

Important

SageMaker 추론에서는 전체 순위 사용자 지정 모델 및 LoRA 병합 모델만 지원됩니다. 병합되지 않은 LoRA 모델 및 기본 모델의 경우 Amazon Bedrock을 사용합니다.

특성

SageMaker 추론에서 Amazon Nova 모델에 대해 사용할 수 있는 기능은 다음과 같습니다.

모델 기능

- 텍스트 생성

배포 및 조정

- 사용자 지정 인스턴스 선택이 포함된 실시간 엔드포인트
- 오토 스케일링 - 트래픽 패턴에 따라 용량을 자동으로 조정하여 비용과 GPU 사용률을 최적화합니다. 자세한 내용은 [Automatically Scale Amazon SageMaker Models](#)를 참조하세요.
- 실시간 토큰 생성을 위한 스트리밍 API 지원

모니터링 및 최적화

- 모니터링 및 알림을 위한 Amazon CloudWatch 통합
- VPC 구성을 통한 가용 영역 인지 지연 시간 최적화

개발 도구

- AWS CLI 지원 - 자세한 내용은 [AWS CLI Command Reference for SageMaker](#)를 참조하세요.
- SDK 지원을 통한 노트북 통합

지원되는 모델 및 인스턴스

SageMaker 추론 엔드포인트를 생성하는 경우 두 가지 환경 변수(CONTEXT_LENGTH 및 MAX_CONCURRENCY)를 설정하여 배포를 구성할 수 있습니다.

- CONTEXT_LENGTH - 요청당 최대 총 토큰 길이(입력 + 출력)
- MAX_CONCURRENCY - 엔드포인트가 지원하는 최대 동시 요청 수

다음 표에는 지원되는 Amazon Nova 모델, 인스턴스 유형 및 지원되는 구성이 나와 있습니다. MAX_CONCURRENCY 값은 각 CONTEXT_LENGTH 설정에서 지원되는 최대 동시성을 나타냅니다.

모델	인스턴스 유형	지원되는 구성
Amazon Nova Micro	ml.g5.12xlarge	CONTEXT_LENGTH: 4000, MAX_CONCURRENCY: 32 CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 16
	ml.g5.24xlarge	CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 32
	ml.g6.12xlarge	CONTEXT_LENGTH: 4000, MAX_CONCURRENCY: 32 CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 16
	ml.g6.24xlarge	CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 32
	ml.g6.48xlarge	CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 32
	ml.p5.48xlarge	CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 32 CONTEXT_LENGTH: 16000, MAX_CONCURRENCY: 2

모델	인스턴스 유형	지원되는 구성
		CONTEXT_LENGTH: 24000, MAX_CONCURRENCY: 1
Amazon Nova Lite	ml.g6.48xlarge	CONTEXT_LENGTH: 4000, MAX_CONCURRENCY: 32
		CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 16
	ml.p5.48xlarge	CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 32
		CONTEXT_LENGTH: 16000, MAX_CONCURRENCY: 2
		CONTEXT_LENGTH: 24000, MAX_CONCURRENCY: 1
Nova 2 Lite	ml.p5.48xlarge	CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 32
		CONTEXT_LENGTH: 16000, MAX_CONCURRENCY: 2
		CONTEXT_LENGTH: 24000, MAX_CONCURRENCY: 1

Note

표시된 MAX_CONCURRENCY 값은 각 CONTEXT_LENGTH 설정의 상한입니다. 동일한 동시성으로 더 짧은 컨텍스트 길이를 사용할 수 있지만, 이러한 값을 초과하면 SageMaker 엔드포인트 생성에 실패합니다.

예를 들어 ml.g5.12xlarge를 사용하는 Amazon Nova Micro의 경우:

- CONTEXT_LENGTH=2000, MAX_CONCURRENCY=32 → 유효
- CONTEXT_LENGTH=8000, MAX_CONCURRENCY=32 → 거부됨(컨텍스트 길이 8,000에서 동시성 제한은 16)

- CONTEXT_LENGTH=8000, MAX_CONCURRENCY=4 → 유효
- CONTEXT_LENGTH=8000, MAX_CONCURRENCY=16 → 유효
- CONTEXT_LENGTH=10000 → 거부됨(이 인스턴스에서 최대 컨텍스트 길이: 8,000)

지원되는 AWS 리전

다음 표에는 SageMaker 추론에서 Amazon Nova 모델을 사용할 수 있는 AWS 리전이 나와 있습니다.

리전 이름	리전 코드	가용성
미국 동부(버지니아 북부)	us-east-1	Available
미국 서부(오리건)	us-west-2	Available

지원되는 컨테이너 이미지

다음 표에는 SageMaker 추론에서 Amazon Nova 모델에 대한 컨테이너 이미지 URI가 리전별로 나와 있습니다. 각 리전에 대해 버전 관리된 태그(v1.0.0) 및 최신 태그(SM-Inference-latest)와 같은 두 가지 이미지 태그를 사용할 수 있습니다. 프로덕션 배포의 경우 버전 관리된 태그를 사용하는 것이 좋습니다.

리전	컨테이너 이미지 URI
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

모범 사례

SageMaker에서 모델을 배포하고 관리하는 모범 사례는 [Best Practices for SageMaker](#)를 참조하세요.

지원

SageMaker 추론에서 Amazon Nova 모델에 대한 지원 및 관련 문제는 콘솔 또는 AWS 계정 관리자를 통해 AWS Support에 문의하세요.

주제

- [시작하기](#)
- [API 참조](#)
- [SageMaker 추론에 호스팅되는 모델 평가](#)
- [Amazon SageMaker 추론 침해 탐지에서 Amazon Nova Forge 모델 배포](#)

시작하기

이 가이드에서는 SageMaker 실시간 엔드포인트에 사용자 지정된 Amazon Nova 모델을 배포하고, 추론 파라미터를 구성하며, 테스트를 위해 모델을 간접 호출하는 방법을 보여줍니다.

사전 조건

다음은 SageMaker 추론에서 Amazon Nova 모델을 배포하기 위한 사전 조건입니다.

- AWS 계정 생성 - 아직 없는 경우 [AWS 계정을 생성](#)합니다.
- 필수 IAM 권한 - IAM 사용자 또는 역할에 다음과 같은 관리형 정책이 연결되어 있는지 확인합니다.
 - AmazonSageMakerFullAccess
 - AmazonS3FullAccess
- 필수 SDK/CLI 버전 - 다음 SDK 버전은 SageMaker 추론에서 Amazon Nova 모델을 사용하여 테스트 및 검증되었습니다.
 - 리소스 기반 API 접근 방식에 대한 SageMaker Python SDK v3.0.0 이상(sagemaker>=3.0.0)
 - API 직접 호출에 대한 Boto3 버전 1.35.0 이상(boto3>=1.35.0). 이 가이드의 예제에서는 이 접근 방식을 사용합니다.
- 서비스 할당량 증가 - SageMaker 추론 엔드포인트(예: m1.p5.48xlarge for endpoint usage)에서 사용하려는 ML 인스턴스 유형에 대한 Amazon SageMaker 서비스 할당량 증가를 요청합니다. 지원되는 인스턴스 유형의 목록은 [the section called “지원되는 모델 및 인스턴스”](#) 섹션을 참조하세요. 증가를 요청하려면 [Requesting a quota increase](#)를 참조하세요. SageMaker 인스턴스 할당량에 대한 자세한 내용은 [SageMaker endpoints and quotas](#)를 참조하세요.

1단계: AWS 자격 증명 구성

다음 방법 중 하나를 사용하여 AWS 자격 증명을 구성합니다.

옵션 1: AWS CLI(권장됨)

```
aws configure
```

메시지가 나타나면 AWS 액세스 키 ID, 시크릿 키 및 기본 리전을 입력합니다.

옵션 2: AWS 자격 증명 파일

~/.aws/credentials를 생성 또는 편집합니다.

```
[default]
aws_access_key_id = YOUR_ACCESS_KEY
aws_secret_access_key = YOUR_SECRET_KEY
```

옵션 3: 환경 변수

```
export AWS_ACCESS_KEY_ID=your_access_key
export AWS_SECRET_ACCESS_KEY=your_secret_key
```

Note

AWS 자격 증명에 대한 자세한 내용은 [구성 및 자격 증명 파일 설정](#)을 참조하세요.

AWS 클라이언트 초기화

다음 코드를 사용하여 Python 스크립트 또는 노트북을 생성해 AWS SDK를 초기화하고 자격 증명을 확인합니다.

```
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.")
```

인증에 성공하면 AWS 계정 ID를 확인하는 출력이 표시됩니다.

2단계: SageMaker 실행 역할 생성

SageMaker 실행 역할은 사용자를 대신하여 모델 아티팩트용 Amazon S3 버킷 및 로깅용 CloudWatch 와 같은 AWS 리소스에 액세스할 권한을 SageMaker에 부여하는 IAM 역할입니다.

실행 역할 생성

Note

IAM 역할을 생성하려면 `iam:CreateRole` 및 `iam:AttachRolePolicy` 권한이 필요합니다. 계속 진행하기 전에 IAM 사용자 또는 역할에 이러한 권한이 있는지 확인합니다.

다음 코드는 Amazon Nova 사용자 지정된 모델을 배포하는 데 필요한 권한을 가진 IAM 역할을 생성합니다.

```
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}")

```

기존 실행 역할 사용(선택 사항)

SageMaker 실행 역할이 이미 있는 경우 대신 다음을 사용할 수 있습니다.

```

# Replace with your existing role ARN
SAGEMAKER_EXECUTION_ROLE_ARN = "arn:aws:iam::YOUR_ACCOUNT_ID:role/
YOUR_EXISTING_ROLE_NAME"

```

계정에서 기존 SageMaker 역할을 찾으려는 경우:

```

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

실행 역할에는 Amazon S3 및 SageMaker 리소스에 액세스할 권한과 `sagemaker.amazonaws.com`과의 신뢰 관계가 있어야 합니다.

SageMaker 실행 역할에 대한 자세한 내용은 [SageMaker Roles](#)를 참조하세요.

3단계: 모델 파라미터 구성

Amazon Nova 모델에 대한 배포 파라미터를 구성합니다. 이러한 설정은 모델 동작, 리소스 할당 및 추론 특성을 제어합니다. 지원되는 인스턴스 유형과 각각에 대해 지원되는 `CONTEXT_LENGTH` 및 `MAX_CONCURRENCY` 값의 목록은 [the section called “지원되는 모델 및 인스턴스”](#) 섹션을 참조하세요.

필수 파라미터

- **IMAGE:** Amazon Nova 추론 컨테이너에 대한 Docker 컨테이너 이미지 URI. 이는 AWS에서 제공됩니다.
- **CONTEXT_LENGTH:** 모델 컨텍스트 길이.
- **MAX_CONCURRENCY:** 반복당 최대 시퀀스 수. GPU의 단일 배치 내에서 동시에 처리할 수 있는 개별 사용자 요청(프롬프트) 수에 대한 제한을 설정합니다. 범위: 0보다 큰 정수.

선택적 생성 파라미터

- **DEFAULT_TEMPERATURE:** 생성 시 무작위성을 제어합니다. 범위: 0.0~2.0(0.0 = 결정적, 높음 = 더 무작위).
- **DEFAULT_TOP_P:** 토큰 선택을 위한 Nucleus 샘플링 임계치. 범위: 1e-10~1.0.
- **DEFAULT_TOP_K:** 가능성이 가장 큰 상위 K개 토큰으로 토큰 선택을 제한합니다. 범위: 정수 -1 이상 (-1 = 제한 없음).
- **DEFAULT_MAX_NEW_TOKENS:** 응답으로 생성할 최대 토큰 수(즉, 최대 출력 토큰). 범위: 정수 1 이상.
- **DEFAULT_LOGPROBS:** 토큰당 반환할 로그 확률 수. 범위: 정수 1~20.

배포 구성

```
# 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}")
```

배포별 파라미터 구성

이제 모델 아티팩트 위치 및 인스턴스 유형 선택을 포함하여 Amazon Nova 모델 배포에 대한 특정 파라미터를 구성합니다.

배포 식별자 설정

```
# Deployment identifier - use a descriptive name for your use case
JOB_NAME = "my-nova-deployment"
```

모델 아티팩트 위치 지정

훈련된 Amazon Nova 모델 아티팩트가 저장되는 Amazon S3 URI를 제공합니다. 이는 모델 훈련 또는 미세 조정 작업의 출력 위치여야 합니다.

```
# 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/"
```

모델 변형 및 인스턴스 유형 선택

```
# 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}")
```

이름 지정 규칙

코드는 AWS 리소스에 대한 일관된 이름을 자동으로 생성합니다.

- 모델 이름: {JOB_NAME}-{model}-{instance-type}
- 엔드포인트 구성: {MODEL_NAME}-Config
- 엔드포인트 이름: {MODEL_NAME}-Endpoint

4단계: SageMaker 모델 및 엔드포인트 구성 생성

이 단계에서는 Amazon Nova 모델 아티팩트를 참조하는 SageMaker 모델 객체와 모델 배포 방법을 정의하는 엔드포인트 구성이라는 두 가지 필수 리소스를 생성합니다.

SageMaker 모델: 추론 컨테이너 이미지, 모델 아티팩트 위치 및 환경 구성을 패키징하는 모델 객체. 이는 여러 엔드포인트에 배포할 수 있는 재사용 가능한 리소스입니다.

엔드포인트 구성: 인스턴스 유형, 인스턴스 수 및 모델 변형을 포함하여 배포를 위한 인프라 설정을 정의합니다. 이를 통해 모델 자체와 별도로 배포 설정을 관리할 수 있습니다.

SageMaker 모델 생성

다음 코드는 Amazon Nova 모델 아티팩트를 참조하는 SageMaker 모델을 생성합니다.

```
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}")
```

키 파라미터:

- **ModelName**: 모델의 고유한 식별자
- **Image**: Amazon Nova 추론을 위한 Docker 컨테이너 이미지 URI
- **ModelDataSource**: 모델 아티팩트의 Amazon S3 위치
- **Environment**: 3단계에서 구성된 환경 변수
- **ExecutionRoleArn**: 2단계의 IAM 역할
- **EnableNetworkIsolation**: 향상된 보안을 위해 True로 설정(컨테이너가 아웃바운드 네트워크 직접 호출을 하지 못하도록 방지)

엔드포인트 구성 생성

그런 다음 배포 인프라를 정의하는 엔드포인트 구성을 생성합니다.

```
# 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}")
```

키 파라미터:

- **VariantName**: 이 모델 변형의 식별자(단일 모델 배포의 경우 'primary' 사용)

- **ModelName**: 위에서 생성된 모델 참조
- **InitialInstanceCount**: 배포할 인스턴스 수(1로 시작, 필요한 경우 나중에 조정)
- **InstanceType**: 3단계에서 선택한 ML 인스턴스 유형

리소스 생성 확인

리소스가 성공적으로 생성되었는지 확인할 수 있습니다.

```
# 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")
```

5단계: 엔드포인트 배포

다음 단계는 SageMaker 실시간 엔드포인트를 생성하여 Amazon Nova 모델을 배포하는 것입니다. 이 엔드포인트는 모델을 호스팅하고 추론 요청을 위해 안전한 HTTPS 엔드포인트를 제공합니다.

엔드포인트 생성은 일반적으로 15~30분이 걸립니다. AWS에서 인프라를 프로비저닝하고, 모델 아티팩트를 다운로드하며, 추론 컨테이너를 초기화하기 때문입니다.

엔드포인트 생성

```
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}")
```

엔드포인트 생성 모니터링

다음 코드는 배포가 완료될 때까지 엔드포인트 상태를 폴링합니다.

```
# 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
```

엔드포인트가 준비되었는지 확인

엔드포인트가 InService 상태가 되면 해당 구성을 확인할 수 있습니다.

```
# 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

```

엔드포인트 생성 실패 문제 해결

일반적인 실패 이유:

- 용량 부족: 요청한 인스턴스 유형을 사용자 리전에서 사용할 수 없음
 - 해결 방법: 다른 인스턴스 유형을 시도하거나 할당량 증가 요청
- IAM 권한: 실행 역할에 필요한 권한이 없음
 - 해결 방법: 역할에 Amazon S3 모델 아티팩트 및 필요한 SageMaker 권한에 대한 액세스 권한이 있는지 확인
- 모델 아티팩트를 찾을 수 없음: Amazon S3 URI가 잘못되었거나 이에 액세스할 수 없음
 - 해결 방법: Amazon S3 URI를 확인하고 버킷 권한을 확인한 다음, 올바른 리전에 있는지 확인
- 리소스 제한: 엔드포인트 또는 인스턴스에 대한 계정 제한을 초과함
 - 해결 방법: Service Quotas 또는 AWS Support를 통해 서비스 할당량 증가 요청

Note

실패한 엔드포인트를 삭제하고 다시 시작해야 하는 경우:


```
sagemaker.delete_endpoint(EndpointName=ENDPOINT_NAME)
```

6단계: 엔드포인트 간접 호출

엔드포인트가 InService 상태가 되면 추론 요청을 전송하여 Amazon Nova 모델에서 예측을 생성할 수 있습니다. SageMaker는 동기식 엔드포인트(스트리밍/비스트리밍 모드에서 실시간) 및 비동기식 엔드포인트(배치 처리를 위한 Amazon S3 기반)를 지원합니다.

런타임 클라이언트 설정

적절한 제한 시간 설정을 사용하여 SageMaker 런타임 클라이언트를 생성합니다.

```
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)
```

범용 추론 함수 생성

다음 함수는 스트리밍 요청과 비스트리밍 요청을 모두 처리합니다.

```
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)}")

```

예제 1: 비스트리밍 채팅 완료

대화형 상호 작용에 채팅 형식을 사용합니다.

```
# 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)
```

샘플 응답:

```
{
  "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
}
}

```

예제 2: 간단한 텍스트 완료

간단한 텍스트 생성에 대한 완료 형식을 사용합니다.

```

# 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)

```

샘플 응답:

```
{
  "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
  }
}
```

예제 3: 스트리밍 채팅 완료

```
# 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)
```

샘플 스트리밍 출력:

```
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]

```

예제 4: 멀티모달 채팅 완료

이미지 및 텍스트 입력에 멀티모달 형식을 사용합니다.

```

# 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)

```

샘플 응답:

```

{
    "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
}
}

```

7단계: 리소스 정리(선택 사항)

불필요한 비용이 발생하지 않도록 이 자습서 중에 생성한 AWS 리소스를 삭제합니다. 추론 요청을 적극적으로 생성하지 않더라도 SageMaker 엔드포인트에서는 실행 중에 요금이 발생합니다.

Important

테이블 삭제는 영구적이며 실행 취소할 수 없습니다. 계속 진행하기 전에 이러한 리소스가 더 이상 필요하지 않은지 확인합니다.

엔드포인트 삭제

```

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

엔드포인트 삭제는 비동기식입니다. 삭제 상태를 모니터링할 수 있습니다.


```
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
```

엔드포인트 구성 삭제

엔드포인트가 삭제된 후 엔드포인트 구성을 제거합니다.

```
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}")
```

모델 삭제

SageMaker 모델 객체를 제거합니다.

```
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}")
```

API 참조

SageMaker의 Amazon Nova 모델은 추론에 대해 표준 SageMaker 런타임 API를 사용합니다. 전체 API 설명서는 [Test a deployed model](#)을 참조하세요.

엔드포인트 간접 호출

SageMaker의 Amazon Nova 모델은 다음과 같은 두 가지 간접 호출 방법을 지원합니다.

- 동기식 간접 호출: 실시간 비스트리밍 추론 요청에 대해 [InvokeEndpoint](#) API를 사용합니다.
- 스트리밍 간접 호출: 실시간 스트리밍 추론 요청에 대해 [InvokeEndpointWithResponseStream](#) API를 사용합니다.

요청 형식

Amazon Nova 모델은 다음과 같은 두 가지 요청 형식을 지원합니다.

채팅 완료 형식

대화형 상호 작용에 대해 다음 형식을 사용합니다.

```
{
  "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
  }
}
```

텍스트 완료 형식

간단한 텍스트 생성에 대해 이 형식을 사용합니다.

```
{
  "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
  }
}
```

멀티모달 채팅 완료 형식

이미지 및 텍스트 입력에 대해 이 형식을 사용합니다.

```
{
  "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
}
```

요청 파라미터

- **messages(배열)**: 채팅 완료 형식의 경우. role 및 content 필드가 있는 메시지 객체의 배열. 콘텐츠는 텍스트 전용 문자열 또는 멀티모달 입력 배열일 수 있습니다.
- **prompt(문자열)**: 텍스트 완료 형식의 경우. 생성할 입력 텍스트.

- `max_tokens`(정수): 응답에서 생성할 최대 토큰 수. 범위: 1 이상.
- `max_completion_tokens`(정수): 채팅 완료에 대한 `max_tokens`의 대안. 생성할 최대 완료 토큰 수.
- `temperature`(float): 생성 시 무작위성을 제어합니다. 범위: 0.0~2.0(0.0 = 결정적, 2.0 = 최대 무작위성).
- `top_p`(float): Nucleus 샘플링 임계치. 범위: 1e-10~1.0.
- `top_k`(정수): 가능성이 가장 큰 상위 K개 토큰으로 토큰 선택을 제한합니다. 범위: -1 이상(-1 = 제한 없음).
- `stream`(부울): 응답 스트리밍 여부. 스트리밍의 경우 `true`, 비스트리밍의 경우 `false`로 설정합니다.
- `logprobs`(부울/정수): 채팅 완료의 경우 부울을 사용합니다. 텍스트 완료의 경우 반환할 로그 확률 수에 정수를 사용합니다. 범위: 1~20.
- `top_logprobs`(정수): 로그 확률을 반환할 가능성이 가장 큰 토큰 수(채팅 완료만 해당).
- `reasoning_effort`(문자열): 추론 노력 수준입니다. 옵션: 'low', 'high'(Nova 2 Lite 사용자 지정 모델의 채팅 완료만 해당).
- `allowed_token_ids`(배열): 생성할 수 있는 토큰 ID 목록. 출력을 지정된 토큰으로 제한합니다.
- `truncate_prompt_tokens`(정수): 제한을 초과하는 경우 프롬프트를 이 많은 토큰으로 자릅니다.
- `stream_options`(객체): 스트리밍 응답에 대한 옵션. 스트리밍 응답에서 토큰 사용량을 포함하도록 `include_usage` 부울을 포함합니다.

응답 형식

응답 형식은 간접 호출 방법 및 요청 유형에 따라 다릅니다.

채팅 완료 응답(비스트리밍)

동기식 채팅 완료 요청의 경우:

```
{
  "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]
}

```

텍스트 완료 응답(비스트리밍)

동기식 텍스트 완료 요청의 경우:

```
{
  "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
    }
  }
}
```

채팅 완료 스트리밍 응답

스트리밍 채팅 완료 요청의 경우 응답은 서버 전송 이벤트(SSE)로 전송됩니다.

```
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]
```


텍스트 완료 스트리밍 응답

스트리밍 텍스트 완료 요청의 경우:

```
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]

```

응답 필드 설명

- **id**: 완료에 대한 고유한 식별자
- **object**: 반환되는 객체 유형('chat.completion', 'text_completion', 'chat.completion.chunk')
- **created**: 완료가 생성된 시간의 Unix 타임스탬프
- **model**: 완료에 사용되는 모델
- **choices**: 완료 선택 배열
- **usage**: 프롬프트, 완료 및 총 토큰을 포함하는 토큰 사용 정보
- **logprobs**: 토큰에 대한 로그 확률 정보(요청 시)
- **finish_reason**: 모델 생성이 중지된 이유('stop', 'length', 'content_filter')
- **delta**: 스트리밍 응답의 증분 콘텐츠
- **reasoning**: reasoning_effort를 사용하는 경우 추론 콘텐츠
- **token_ids**: 생성된 텍스트에 대한 토큰 ID 배열

전체 API 설명서는 [InvokeEndpoint API 참조](#) 및 [InvokeEndpointWithResponseStream API 참조](#)를 참조하세요.

SageMaker 추론에 호스팅되는 모델 평가

이 가이드에서는 오픈 소스 평가 프레임워크인 [Inspect AI](#)를 사용하여 SageMaker 추론 엔드포인트에 배포된 사용자 지정된 Amazon Nova 모델을 평가하는 방법을 설명합니다.

Note

실습 연습은 [SageMaker Inspect AI quickstart notebook](#)을 참조하세요.

개요

AI 연구 커뮤니티의 표준화된 벤치마크를 사용하여 SageMaker 엔드포인트에 배포된 사용자 지정된 Amazon Nova 모델을 평가할 수 있습니다. 이 접근 방식을 사용하면 다음을 수행할 수 있습니다.

- 사용자 지정된 Amazon Nova 모델(미세 조정, 종류 또는 기타 적응)을 대규모로 평가
- 여러 엔드포인트 인스턴스에서 병렬 추론을 사용하여 평가 실행
- MMLU, TruthfulQA 및 HumanEval과 같은 벤치마크를 사용하여 모델 성능 비교
- 기존 SageMaker 인프라와 통합

지원되는 모델

SageMaker 추론 공급자는 다음과 함께 작동합니다.

- Amazon Nova 모델(Nova Micro, Nova Lite, Nova Lite 2)
- vLLM 또는 OpenAI 호환 추론 서버를 통해 배포된 모델
- OpenAI 채팅 완료 API 형식을 지원하는 모든 엔드포인트

사전 조건

시작하기 전에 다음을 갖추었는지 확인하세요.

- SageMaker 엔드포인트를 생성하고 간접 호출할 권한이 있는 AWS 계정
- AWS CLI, 환경 변수 또는 IAM 역할을 통해 구성된 AWS 자격 증명
- Python 3.9 이상

필수 IAM 권한

IAM 사용자 또는 역할에 다음 권한이 필요합니다.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "sagemaker:InvokeEndpoint",
        "sagemaker:DescribeEndpoint"
      ],
      "Resource": "arn:aws:sagemaker:*:*:endpoint/*"
    }
  ]
}
```

1단계: SageMaker 엔드포인트 배포

평가를 실행하기 전에 모델을 실행하는 SageMaker 추론 엔드포인트가 필요합니다.

Amazon Nova 모델을 사용하여 SageMaker 추론 엔드포인트를 생성하는 방법에 대한 지침은 [the section called “시작하기”](#) 섹션을 참조하세요.

엔드포인트가 InService 상태가 되면 평가 명령에 사용할 엔드포인트 이름을 기록합니다.

2단계: 평가 종속 항목 설치

Python 가상 환경을 생성하고 필요한 패키지를 설치합니다.

```
# 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
```

3단계: AWS 자격 증명 구성

다음과 같은 인증 방법 중 하나를 선택합니다.

옵션 1: AWS CLI(권장됨)

```
aws configure
```

메시지가 나타나면 AWS 액세스 키 ID, 시크릿 액세스 키 및 기본 리전을 입력합니다.

옵션 2: 환경 변수

```
export AWS_ACCESS_KEY_ID=your_access_key
export AWS_SECRET_ACCESS_KEY=your_secret_key
export AWS_DEFAULT_REGION=us-west-2
```

옵션 3: IAM 역할

Amazon EC2 또는 SageMaker 노트북에서 실행하는 경우 인스턴스의 IAM 역할이 자동으로 사용됩니다.

자격 증명 확인

```
import boto3

sts = boto3.client('sts')
identity = sts.get_caller_identity()
print(f"Account: {identity['Account']}")
print(f>User/Role: {identity['Arn']}")
```

4단계: SageMaker 공급자 설치

SageMaker 공급자를 사용하면 Inspect AI가 SageMaker 엔드포인트와 통신할 수 있습니다. 공급자 설치 프로세스는 [quickstart notebook](#)에서 간소화됩니다.

5단계: 평가 벤치마크 다운로드

Inspect Evals 리포지토리를 복제하여 표준 벤치마크에 액세스합니다.

```
git clone https://github.com/UKGovernmentBEIS/inspect_evals.git
```

이 리포지토리에는 다음과 같은 벤치마크가 포함되어 있습니다.

- MMLU 및 MMLU-Pro(지식 및 추론)
- TruthfulQA(진실성)
- HumanEval(코드 생성)
- GSM8K(수학 추론)

6단계: 평가 실행

SageMaker 엔드포인트를 사용하여 평가를 실행합니다.

```
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
```

주요 파라미터

파라미터	기본값	설명
--max-connections	10	엔드포인트에 대한 병렬 요청 수. 인스턴스 수에 따라 조정합니다(예: 인스턴스 10개 × 25 = 250).
--max-retries	3	실패한 요청에 대해 재시도합니다. 대규모 평가의 경우 50~100을 사용합니다.
-M region_name	us-east-1	엔드포인트가 배포된 AWS 리전.
-M read_timeout	600	요청 제한 시간(초).
-M connect_timeout	60	연결 제한 시간(초).

조정 권장 사항

다중 인스턴스 엔드포인트의 경우:

```
# 10-instance endpoint example
--max-connections 250    # ~25 connections per instance
--max-retries 100       # Handle transient errors
```

--max-connections를 너무 높게 설정하면 엔드포인트가 압도되어 스로틀링이 발생할 수 있습니다. 너무 낮게 설정하면 용량이 적게 사용됩니다.

7단계: 결과 보기

Inspect AI 뷰어를 시작하여 평가 결과를 분석합니다.

```
inspect view
```

뷰어에 다음이 표시됩니다.

- 전체 점수 및 지표
- 모델 응답이 포함된 샘플별 결과
- 오류 분석 및 실패 패턴

엔드포인트 관리

엔드포인트 업데이트

기존 엔드포인트를 새 모델 또는 구성으로 업데이트하는 방법:

```
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
)
```

엔드포인트 삭제

```
sagemaker.delete_endpoint(EndpointName=ENDPOINT_NAME)
```

사용자 지정 벤치마크 온보딩

다음 워크플로를 사용하여 Inspect AI에 새 벤치마크를 추가할 수 있습니다.

1. 벤치마크의 데이터세트 형식 및 평가 지표 연구
2. `inspect_evals/`에서 유사한 구현 검토
3. 데이터세트 레코드를 Inspect AI 샘플로 변환하는 태스크 파일 생성
4. 적절한 솔버 및 점수 계산기 구현
5. 소규모 테스트 실행으로 검증

태스크 구조 예제:

```
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()
    )
```

문제 해결

일반적인 문제

엔드포인트 스로틀링 또는 제한 시간

- `--max-connections` 감소
- `--max-retries` 증가
- 엔드포인트 CloudWatch 지표에서 용량 문제 확인

인증 오류

- AWS 자격 증명이 올바르게 구성되었는지 확인
- IAM 권한에 `sagemaker:InvokeEndpoint`가 포함되었는지 확인

모델 오류

- 엔드포인트가 InService 상태인지 확인
- 모델이 OpenAI 채팅 완료 API 형식을 지원하는지 확인

관련 리소스

- [Inspect AI 설명서](#)
- [평가 리포지토리 검사](#)
- [SageMaker 개발자 안내서](#)
- [추론 모델 배포](#)
- [AWS CLI 구성](#)

Amazon SageMaker 추론 침해 탐지에서 Amazon Nova Forge 모델 배포

AWS에서는 AI를 책임감 있게 사용하기 위해 최선을 다하고 있습니다. 잠재적 오용을 방지하기 위해 Amazon SageMaker 추론에서 Amazon Nova Forge 모델을 배포할 때 SageMaker 추론은 자동 침해 탐지 메커니즘을 구현하여 [책임 있는 AI](#) 정책을 포함하여 AWS의 [이용 정책](#)(AUP) 및 서비스 약관과 관련 잠재적 위반을 식별합니다.

침해 탐지 메커니즘은 완전히 자동화되어 있으므로, 사용자 입력 또는 모델 출력을 사람이 검토하거나 액세스할 필요가 없습니다.

자동 침해 탐지 기능은 다음과 같습니다.

- 콘텐츠 분류 - 분류자를 사용하여 사용자 입력 및 모델 출력에 있는 유해한 콘텐츠(예: 폭력을 조장하는 콘텐츠)를 탐지합니다. 분류자는 모델 입력 및 출력을 처리하고 유해성의 유형과 신뢰도를 할당하는 알고리즘입니다. Amazon Nova Forge 모델 사용량에서 이러한 분류자를 실행할 수 있습니다. 분류 프로세스는 자동화되어 있으며 사용자 입력 또는 모델 출력을 사람이 검토하지 않습니다.
- 패턴 식별 - 분류자 지표를 사용하여 잠재적 위반과 반복되는 행동을 식별합니다. 식명화된 분류자 지표를 컴파일하고 공유할 수 있습니다. Amazon SageMaker 추론은 사용자 입력 또는 모델 출력을 저장하지 않습니다.
- 아동 성착취물(CSAM) 탐지 및 차단 - 사용자 (및 최종 사용자)가 Amazon SageMaker 추론에 업로드하는 콘텐츠에 대한 책임은 사용자 본인에게 있으며 이 콘텐츠에 불법 이미지가 없는지 확인해야 합니다. Amazon SageMaker 추론에서 Amazon Nova Forge 모델을 배포할 때 SageMaker는 CSAM의 배포를 중지하기 위해 자동 침해 탐지 메커니즘(해시 매칭 기술 또는 분류자 등)을 사용하여 명백한

CSAM을 탐지할 수 있습니다. Amazon SageMaker 추론에서 이미지 입력에서 명백한 CSAM을 탐지하면 Amazon SageMaker 추론에서 요청을 차단하고 사용자는 자동 오류 메시지를 받게 됩니다. Amazon SageMaker 추론은 National Center for Missing and Exploited Children(NCMEC) 또는 관련 기관에 보고서를 제출할 수도 있습니다. 당사는 CSAM을 심각한 사안으로 간주하므로 감지, 차단, 보고 메커니즘을 계속해서 업데이트할 예정입니다. 관련 법률에 따라 추가 조치를 취해야 할 수 있으며 이러한 조치에 대한 책임은 사용자에게 있습니다.

자동 침해 탐지 메커니즘으로 잠재적 위반 사항이 식별되면 당사는 사용자의 Amazon SageMaker 추론 사용 및 당사 서비스 약관 준수에 대한 정보를 요청할 수 있습니다. 사용자가 본 약관 또는 정책을 준수하지 않거나 준수할 수 없는 경우 AWS는 Amazon SageMaker 추론에 대한 사용자의 액세스 권한을 일시 중단할 수 있습니다. 또한 자동 테스트에서 모델 응답이 약관 및 정책과 일치하지 않는 것으로 탐지되는 경우에도 실패한 추론 작업에 대한 요금이 청구될 수 있습니다.

추가적인 질문이 있을 경우 AWS Support에 문의하시기 바랍니다. 자세한 내용은 [Amazon SageMaker FAQ](#)를 참조하세요.

Amazon Bedrock 추론

Amazon Nova 모델을 훈련하고 테스트한 후에는 프로덕션 규모의 추론을 위해 Amazon Bedrock에 모델을 배포할 수 있습니다. 배포 프로세스에는 CreateCustomModel API를 사용하여 Amazon Bedrock 모델을 생성하고, 관리형 Amazon S3 버킷에서 모델 아티팩트로 모델 아티팩트를 내보낸 다음, 모델이 ACTIVE 상태이면 온디맨드 또는 프로비저닝된 처리량 추론으로 엔드포인트를 구성하는 작업이 포함됩니다.

SageMaker에서 사용자 지정 모델을 생성한 후 CreateCustomModel API를 사용하여 SageMaker 에스크로에서 Amazon Bedrock에 이를 배포하여 추론을 실행할 수 있습니다. 그런 다음 CreateCustomModelDeployment를 사용하여 OD 추론 엔드포인트를 생성하거나 파라미터 효율 미세 조정(PEFT) 모델에 대해 프로비저닝된 처리량 추론을 설정할 수 있습니다. 전체 순위 사용자 지정 모델에 대해 프로비저닝된 처리량 추론을 설정할 수 있습니다.

Amazon Nova Forge SDK를 사용하여 사용자 지정 Amazon Nova 모델을 배포할 수도 있습니다. Amazon Nova Forge SDK는 훈련 작업 또는 S3 모델 체크포인트에서 관련 정보를 추출하여 Amazon Bedrock에 게시할 수 있는 간소화된 환경을 제공합니다. 자세한 내용은 [Amazon Nova Forge SDK](#)를 참조하세요.

사용자 지정 모델에 대한 Amazon Bedrock 추론을 설정하는 자세한 단계는 [Amazon Bedrock에 사용자 지정 Amazon Nova 모델 배포](#)를 참조하세요.

다음 섹션에서는 사용자 지정 모델에서 온디맨드 추론을 자세히 설명합니다.

사용자 지정 모델 온디맨드 추론용 배포

모델 사용자 지정 작업(미세 조정, 증류, 또는 지속적 사전 학습)을 통해 사용자 지정 모델을 성공적으로 생성한 후, 해당 모델에 대해 온디맨드 추론을 설정할 수 있습니다.

사용자 지정 모델의 온디맨드 추론을 설정하려면, 사용자 지정 모델 배포를 통해 모델을 배포해야 합니다. 모델을 배포한 후에는 배포된 모델의 Amazon 리소스 이름(ARN)을 InvokeModel 또는 Converse API 작업에서 modelId 파라미터로 사용합니다. 배포된 모델은 Amazon Bedrock의 플레이그라운드, 에이전트, 지식 베이스 등의 기능에서 온디맨드 추론용으로 활용할 수 있습니다.

주제

- [지원되는 모델](#)
- [사용자 지정 모델 배포](#)
- [온디맨드 추론용 배포 사용](#)
- [사용자 지정 모델 배포 삭제](#)

지원되는 모델

다음 모델에 대해 온디맨드 추론을 설정할 수 있습니다.

- Amazon Nova Canvas
- Amazon Nova Lite
- Amazon Nova Micro
- Amazon Nova Pro

사용자 지정 모델 배포

사용자 지정 모델은 Amazon Bedrock 콘솔, AWS Command Line Interface 또는 AWS를 사용하여 배포할 수 있습니다. 배포를 추론에 활용하는 방법에 대한 자세한 내용은 [온디맨드 추론용 배포 사용](#)을 참조하세요.

주제

- [사용자 지정 모델 배포\(콘솔\)](#)
- [사용자 지정 모델 배포\(AWS Command Line Interface\)](#)
- [사용자 지정 모델 배포\(AWS SDK\)](#)

사용자 지정 모델 배포(콘솔)

사용자 지정 모델은 사용자 지정 모델 페이지에서 다음과 같이 배포할 수 있습니다. 동일한 필드를 사용하여 온디맨드 사용자 지정 모델 페이지에서도 모델을 배포할 수 있습니다. 이 페이지를 찾으려면 탐색 창에서 추론 및 평가 아래의 온디맨드 사용자 지정 모델을 선택합니다.

사용자 지정 모델 배포 방법

1. [Amazon Bedrock 권한이 있는 IAM 역할](https://console.aws.amazon.com/nova/)을 사용하여 AWS Management Console에 로그인하고 <https://console.aws.amazon.com/nova/>에서 Amazon Bedrock 콘솔을 엽니다.
2. 왼쪽 탐색 창의 파운데이션 모델에서 사용자 지정 모델을 선택합니다.
3. 모델 탭에서 배포할 모델의 라디오 버튼을 선택합니다.
4. 추론 설정과 온디맨드 배포를 차례로 선택합니다.
5. 배포 세부 정보에서 다음 정보를 입력합니다.
 - 배포 이름(필수) - 배포의 고유 이름을 입력합니다.
 - 설명(선택 사항) - 배포에 대한 설명을 입력합니다.
 - 태그(선택 사항) - 비용 할당 및 리소스 관리를 위해 태그를 추가합니다.
6. 생성(Create)을 선택합니다. 배포 상태가 Completed가 되면, 사용자 지정 모델을 온디맨드 추론에 사용할 준비가 완료된 것입니다. 사용자 지정 모델 사용 방법에 대한 자세한 내용은 [온디맨드 추론용 배포 사용](#)을 참조하세요.

사용자 지정 모델 배포(AWS Command Line Interface)

AWS Command Line Interface를 사용하여 사용자 지정 모델을 온디맨드 추론용으로 배포하려면, 사용자 지정 모델의 Amazon 리소스 이름(ARN)을 사용하여 `create-custom-model-deployment` 명령어를 실행합니다. 이 명령은 [CreateCustomModelDeployment](#) API 작업을 사용합니다. 실행 결과로 반환되는 배포의 ARN을 추론 요청 시 `modelId`로 사용할 수 있습니다. 배포를 추론에 활용하는 방법에 대한 자세한 내용은 [온디맨드 추론용 배포 사용](#)을 참조하세요.

```
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

```

사용자 지정 모델 배포(AWS SDK)

온디맨드 추론을 위해 사용자 지정 모델을 배포하려면, 사용자 지정 모델의 Amazon 리소스 이름 (ARN)과 함께 [CreateCustomModelDeployment](#) API 작업을 사용합니다. 실행 결과로 반환되는 배포의 ARN을 추론 요청 시 `modelId`로 사용할 수 있습니다. 배포를 추론에 활용하는 방법에 대한 자세한 내용은 [온디맨드 추론용 배포 사용](#)을 참조하세요.

다음 코드는 Python용 SDK(Boto3)를 사용하여 사용자 지정 모델을 배포하는 방법을 보여줍니다.

```

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

```

온디맨드 추론용 배포 사용

사용자 지정 모델을 온디맨드 추론용으로 배포한 후에는 추론 요청을 보내 응답을 생성할 수 있습니다. InvokeModel 또는 Converse 작업을 사용할 때는 배포된 모델의 Amazon 리소스 이름(ARN)을 modelId로 지정합니다.

추론 요청 방법에 대한 자세한 내용은 다음 주제를 참조하세요.

- [모델 추론을 사용하여 프롬프트 제출 및 응답 생성](#)
- [모델 추론 실행을 위한 사전 조건](#)
- [API를 사용하여 프롬프트 제출 및 응답 생성](#)

사용자 지정 모델 배포 삭제

온디맨드 추론에 모델 사용을 마친 후에는 배포를 삭제할 수 있습니다. 배포를 삭제하면 해당 배포를 온디맨드 추론에 사용할 수 없지만, 기본 사용자 지정 모델 자체가 삭제되지는 않습니다.

사용자 지정 모델은 Amazon Bedrock 콘솔, AWS Command Line Interface 또는 AWS SDK를 사용하여 삭제할 수 있습니다.

Important

사용자 지정 모델 배포 삭제는 되돌릴 수 없는 작업입니다. 삭제를 진행하기 전에 해당 배포가 더 이상 필요하지 않은지 반드시 확인합니다. 동일한 사용자 지정 모델을 다시 온디맨드 추론에 사용하려면, 새로운 배포를 생성해야 합니다.

주제

- [사용자 지정 모델 배포 삭제\(콘솔\)](#)
- [사용자 지정 모델 배포 삭제\(AWS Command Line Interface\)](#)
- [사용자 지정 모델 배포 삭제\(AWS SDK\)](#)

사용자 지정 모델 배포 삭제(콘솔)

사용자 지정 모델 배포를 삭제하려면 다음 단계를 수행합니다.

1. 탐색 창에서 추론 및 평가 아래의 온디맨드 사용자 지정 모델을 선택합니다.
2. 삭제하려는 사용자 지정 모델 배포를 선택합니다.
3. 삭제를 선택합니다.
4. 확인 대화 상자에서 삭제를 확인하기 위해 배포 이름을 입력합니다.
5. [삭제]를 선택하여 확인합니다.

삭제가 진행되는 동안 배포 상태가 Deleting로 변경됩니다. 삭제가 완료되면 해당 배포는 목록에서 제거됩니다.

사용자 지정 모델 배포 삭제(AWS Command Line Interface)

AWS Command Line Interface를 사용하여 사용자 지정 모델 배포를 삭제하려면, `delete-custom-model-deployment` 명령어와 배포 식별자를 사용합니다.

```
aws bedrock delete-custom-model-deployment \
  --custom-model-deployment-identifier "deployment-arn-or-name" \
  --region region
```

사용자 지정 모델 배포 삭제(AWS SDK)

프로그래밍 방식으로 사용자 지정 모델 배포를 삭제하려면, 배포의 Amazon 리소스 이름(ARN) 또는 이름을 사용하여 [DeleteCustomModelDeployment](#) API 작업을 호출합니다. 다음 코드는 Python용 SDK(Boto3)를 사용하여 사용자 지정 모델 배포를 삭제하는 방법을 보여줍니다.

```
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

```

사용자 지정 모델에 대한 온디맨드 추론

온디맨드(OD) 추론을 사용하면, 프로비저닝된 처리량 엔드포인트를 유지하지 않고도 사용자 지정 Amazon Nova 모델에서 추론을 실행할 수 있습니다. 이를 통해 비용을 최적화하고 효율적으로 확장할 수 있습니다. 온디맨드 추론 사용 시 입력 및 출력 토큰 수를 기준으로 사용량에 따라 요금이 청구됩니다.

호환성 요구 사항

다음과 같은 호환성 요구 사항이 적용됩니다.

- Amazon Nova Pro, Lite, Micro 사용자 지정 이해 모델에서 OD 추론을 지원합니다. Nova 사용자 지정 콘텐츠 생성 모델에서는 OD 추론을 지원하지 않습니다.
- 2025년 7월 16일 이후에 학습된 Amazon Nova 사용자 지정 이해 모델에서만 OD 추론을 지원합니다. 2025년 7월 16일 이전에 학습된 사용자 지정 모델은 OD 추론과 호환되지 않습니다.
- Amazon Bedrock 사용자 지정: Amazon Bedrock 사용자 지정을 사용해 만든 모델과 Amazon Bedrock을 사용해 교사 모델로부터 증류한 학생 모델에서 OD 추론을 지원합니다.
- SageMaker AI 사용자 지정: SageMaker AI에서 사용자 지정한 모델 중 Amazon Bedrock에서 호스팅되는 파라미터 효율적 미세 조정(PEFT) 모델에서만 OD 추론을 지원합니다. 여기에는 직접 선호 최적화 + PEFT 모델이 포함됩니다. 전체 순위 미세 조정 모델에서는 OD 추론을 지원하지 않습니다.

모델 훈련 및 추론

2025년 7월 16일 이후 Amazon Bedrock 또는 SageMaker AI에서 PEFT를 사용해 새로운 Amazon Nova Pro, Lite, 또는 Micro 모델을 학습하면, 해당 모델은 프로비저닝된 추론 옵션과 온디맨드 추론 옵션 모두와 자동으로 호환됩니다. 모델 배포 시 원하는 추론 방식을 선택할 수 있습니다.

2025년 7월 16일 이후 학습한 모델에서 OD 추론을 사용하는 방법:

1. [Amazon Bedrock 사용자 지정 API](#) 또는 [SageMaker AI 사용자 지정 API](#)를 사용해 새로운 미세 조정 작업을 생성합니다.
2. [CreateCustomModel API](#)를 사용해 새로 학습한 모델을 Amazon Bedrock에 배포합니다.
3. CustomModelDeployment API를 사용해 온디맨드 추론을 위한 배포를 수행합니다.

속도 제한

온디맨드 추론 요청에는 다음과 같은 분당 요청 수(RPM) 및 분당 토큰 수(TPM) 제한이 적용됩니다.

Base Model for Custom Model	RPM per Custom Model Deployment	TPM per Custom Model Deployment
Nova 2 Lite	2,000	4,000,000

Amazon Nova의 가용 할당량에 대한 자세한 내용은 [Amazon Nova 할당량](#) 섹션을 참조하세요.

Latency

기본 모델 호출과 어댑터 간에는 엔드 투 엔드 지연 시간 차이, 즉 첫 토큰 생성까지 걸리는 시간(TTFT)이 약 20~55% 발생할 수 있습니다. 정확한 지연 시간 값은 모델 크기에 따라 달라지며, 업계 표준에 부합합니다.

Amazon Nova 모델 사용자 지정 제한 사항

Amazon Nova 사용자 지정은 SageMaker에서 다음 기능을 지원하지 않습니다.

- 인스턴스에 SSH로 연결하여 지표 찾기

보안 제어로 인해 훈련 중인 algo-1 인스턴스의 마스터 노드에 SSH로 연결하여 메모리 통계 또는 NVIDIA 통계를 찾거나 훈련 단계를 검증할 수 없습니다.

- SageMaker 트레이너 SDK 지원

SageMaker 트레이너는 현재 훈련 작업을 시작할 수 없습니다. 현재는 예측기 API를 통해서만 훈련 작업을 시작할 수 있습니다.

- SageMaker 훈련 작업에서 웹 풀 액세스 불가

보안 제어로 인해 SageMaker 웹 풀을 사용하여 인스턴스를 Time to Live(TTL)까지 웹 풀에 유지할 수 없습니다.

- 사용자 지정 모델 병합

현재 여러 모델 병합은 지원되지 않습니다. 즉, 여러 LoRA 어댑터를 생성하고 기본 모델을 사용하여 다중 병합 작업을 수행할 수 없습니다.

- 지원되는 관찰성 도구

[TensorBoard](#)는 SageMaker 훈련 작업에 대한 지표를 볼 수 있도록 지원되는 유일한 관찰성 도구입니다. [MLFlow](#) 또는 [WandB](#)는 현재 지원되지 않습니다. SageMaker에서 TensorBoard를 사용하는 방법에 대한 자세한 내용은 [TensorBoard in SageMaker](#)를 참조하세요.

Amazon Nova Forge

Amazon Nova Forge는 Nova를 사용하여 프론티어 모델을 빌드하는 가장 쉽고 비용 효율적인 방법을 조직에 제공하는 최초의 서비스입니다.

Amazon Nova Forge는 '개방 훈련' 모델의 개념을 도입하여 다양한 초기 모델 체크포인트에 대한 액세스 권한과 모델 훈련의 모든 단계에서 독점 데이터를 Amazon에서 선별한 데이터세트와 혼합할 수 있는 기능을 조직에 제공합니다. 이를 통해 모델은 추론과 같은 기초적인 기술을 잊을 위험을 최소화하면서 독점 데이터에서 학습을 극대화할 수 있습니다.

Nova Forge는 다음과 같은 주요 기능을 제공합니다.

- 모델 개발의 모든 단계에서 체크포인트에 액세스하고 새로운 Nova 모델을 광범위하게 사용하기 전에 활용
- 독점 데이터를 Amazon Nova에서 선별한 훈련 데이터와 혼합
- 환경에서 보상 기능을 사용하여 강화 학습 수행
- 시각적 워크플로 또는 명령줄 인터페이스를 통해 Nova를 사용해 빌드하도록 최적화된 푸시 버튼 레시피 사용
- 책임 있는 AI 툴킷을 사용하여 훈련 프로세스 중에 모델을 Amazon Nova의 책임 있는 AI 지침에 맞춘고 추론 중에 모델 응답을 조정하기 위한 런타임 제어를 구현합니다.

사전 조건

주제

- [Nova Forge 구독](#)
- [기타 사전 조건](#)

Nova Forge 구독

Amazon Nova Forge 서비스에 대한 액세스를 요청하려면 콘솔 IAM 역할에 키가 `forge-subscription`이고 값이 `true`인 태그를 추가합니다. 이 태그를 역할에 추가한 후 SageMaker AI 콘솔 > 모델 훈련 및 사용자 지정으로 이동하여 Nova Forge를 클릭합니다. 이 페이지에서는 서비스, 요금 정보 및 기능에 대한 세부 정보를 확인할 수 있습니다. 이 페이지에서 구독을 요청한 다음 구독을 관리할 수 있습니다.

1. 역할에는 `ListAttachedRolePolicy` API를 직접 호출할 권한이 있어야 하며 응답에는 `AdministratorAccess` 또는 `AmazonSageMakerFullAccess` 정책이 포함되어야 합니다.

- 로그인 역할에는 ListRoleTags API를 직접 호출할 권한이 있어야 하며 응답 태그에는 `tag.key=forge-subscription`이 포함되어야 합니다.

기타 사전 조건

또한 다음 사전 조건이 완료되었는지 확인합니다.

- [일반적인 사전 조건](#)
- 사용자를 위한 추가 단계: SageMaker HyperPod 클러스터에 제한된 인스턴스 그룹(RIG) 추가(완료하려면 [여기](#) 단계 수행)

Nova Forge 액세스 및 설정

Nova Forge에 온보딩하려면 다음 2단계 프로세스를 따릅니다.

- 1단계: Nova Forge 구독
- 2단계: HyperPod 인프라 설정

Nova Forge 문서 가져오기

Nova Forge 문서를 가져오려면 아래 단계를 따릅니다.

```
mkdir NovaForgeHyperpodCLI
cd NovaForgeHyperpodCLI
aws s3 cp s3://nova-forge-c7363-206080352451-us-east-1/v1/ ./ --recursive
pip install -e .
```

1단계: Nova Forge 구독

빠른 요약:

- Amazon Web Services 계정에 대한 관리자 액세스 권한이 있는지 확인하세요.
- SageMaker AI 콘솔로 이동하여 Nova Forge에 대한 액세스를 요청하세요.
- 구독 요청이 승인되면 Nova 팀이 확인 이메일을 보낼 때까지 기다리세요.
- 실행 역할에 `forge-subscription` 태그를 지정하세요. 이 태그는 Nova Forge 기능 및 체크포인트에 액세스하는 데 필요합니다. 실행 역할에 다음 태그를 추가하세요.

- 𐏊: forge-subscription
- 𐏋: true

상세 가이드

Nova Forge를 구독하고 사용자 지정 서비스를 효과적으로 사용하려면 Amazon Web Services 고객이 Amazon Web Services 계정에 대한 관리자 액세스 권한을 보유하거나 관리자가 고객에게 관리자 액세스 권한을 부여해야 합니다. 이 문서에서는 다음을 수행하는 데 필요한 단계를 간략하게 설명합니다.

- 관리자 액세스 보안
- Nova Forge를 구독하기 위해 정책 설정
- 사용자 지정 레시피에 액세스
- 사용자 지정 구성
- 워크플로 모니터링
- 사용자 지정된 모델 체크포인트 평가

옵션 A

흐름 1: 계정 사용자는 계정 관리자에게 문의하여 다음을 요청해야 합니다.

- IAM을 통해 계정에 `forge-subscription` 태그를 추가합니다(단계는 부록 A 참조).
- IAM을 통해 `ListRoleTags` 및 `ListAttachedRolePolicies` 권한을 추가합니다(단계는 부록 B 참조).

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

옵션 B

흐름: 계정 사용자는 계정 관리자에게 문의하여 계정에 대한 관리자 액세스를 요청해야 합니다.


- 관리자 액세스 권한이 부여되면 흐름 2의 단계를 따릅니다.

흐름 2. 관리자 액세스 권한이 있는 Amazon Web Services 계정


- IAM을 통해 계정에 forge-subscription 태그를 추가합니다. 부록 A의 단계 참조

부록 A. Amazon Web Services 계정에 forge-subscription 정책 추가


1. Amazon Web Services IAM 대시보드로 이동하세요. 왼쪽에서 역할을 클릭하세요. 관리자를 검색하고 관리자 역할을 클릭하세요.




2. <AssumedRoleToUse>(예: libsAdminAccess)를 선택하세요. 태그 탭을 클릭하세요.



3. 관리 탭을 클릭하세요. 새 태그를 추가하세요. 키 아래에 'forge-subscription'을 입력하고 변경 사항 저장을 클릭하세요.




4. 태그 섹션에 forge-subscription이 키로 표시되는지 확인하세요.




부록 B. 관리자에 의해 비관리자 역할의 Amazon Web Services 계정에 ListRoleTags 및 ListAttachedPolicies 정책 추가

1. Amazon Web Services IAM 대시보드로 이동하세요. 왼쪽에서 역할을 클릭하세요. <AssumedRoleToUse>(예: ForgeAccessRole)를 검색하고 <AssumedRoleToUse>(예: ForgeAccessRole) 역할을 클릭하세요.



2. <AssumedRoleToUse>(예: ForgeAccessRole) 역할을 클릭하고 태그를 선택하세요. 'forge-subscription' 유형의 새 태그를 추가하세요.



3. 권한에서 새 권한 추가: 권한 추가 → 인라인 정책 생성 → 아래에 나열된 다음 정책 추가

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
```

```

        "Sid": "VisualEditor0",
        "Effect": "Allow",
        "Action": [
            "iam:ListRoleTags",
            "iam:ListAttachedRolePolicies"
        ],
        "Resource": "*"
    }
]
}

```

ForgeAccessRole [Info](#)

Summary

Creation date December 09, 2025, 21:31 (UTC-05:00)	ARN arn:aws:iam::i
Last activity 15 minutes ago	Maximum session 1 hour

[Permissions](#) |
 [Trust relationships](#) |
 [Tags \(1\)](#) |
 [Last Accessed](#) |
 [Revoke sessi](#)

Permissions policies (2) [Info](#)

You can attach up to 10 managed policies.

Q Search

- ☐ Policy name ↗
- ☐ AmazonSageMakerFullAccess
- ☐ forge-access-role

forge-access-role

```

1- {
2-   "Version": "2012-10-17",
3-   "Statement": [
4-     {
5-       "Sid": "VisualEditor0",
6-       "Effect": "Allow",
7-       "Action": [
8-         "iam:ListRoleTags",
9-         "iam:ListAttachedRolePolicies"
10-      ],
11-       "Resource": "*"
12-     }
13-   ]
14- }
    
```

2단계. HyperPod 인프라 설정

Forge 지원 기능으로 환경을 구성하기 위한 [워크숍 지침](#)에 따라 필요한 인프라를 설정합니다.

콘텐츠 조정 설정

Nova Forge에 액세스해야 하는 경우 Amazon Nova Lite 1.0 및 Pro 1.0 모델에서 사용자 지정 가능한 콘텐츠 조정 설정(CCMS)을 사용할 수 있습니다. CCMS를 사용하면 특정 비즈니스 요구 사항에 맞게 콘텐츠 조정 제어를 조정하는 동시에 핵심적인 책임 있는 AI 보호를 유지 관리할 수 있습니다. 비즈니스 모델이 CCMS에 적합한지 확인하려면 AWS 계정 관리자에게 문의하세요.

사용자 지정 모델에서 CCMS를 구성하고 사용하는 방법에 대한 자세한 내용은 [책임 있는 AI 도구 키트 및 콘텐츠 조정 섹션](#)을 참조하세요.

지속적인 사전 훈련 및 중간 훈련

Note

구독하면 세부 설명서가 제공됩니다.

Nova Forge CPT는 중간 체크포인트에 대한 액세스 및 Nova의 사전 훈련 코퍼스와 데이터 혼합을 포함하여 표준 CPT 이상의 고급 기능을 제공합니다. 이러한 기능을 사용하면 도메인 적응의 효율성을 높이고 모델의 일반 기능을 더 잘 유지할 수 있습니다.

중간 체크포인트란 무엇이며 왜 필요한가요?

중간 체크포인트는 모델이 최종 프로덕션 준비 상태에 도달하기 전에 사전 훈련의 여러 단계에 저장된 Amazon Nova 모델의 스냅샷입니다. 모델 개발 중에 Amazon Nova는 일정한 학습 속도의 초기 사전 훈련, 학습 속도 감소, 컨텍스트 확장 훈련, 마지막으로 지침 준수 조정 및 안전 훈련과 같은 여러 훈련 단계를 거칩니다. CPT의 경우 중간 체크포인트는 최종 프로덕션 체크포인트보다 선호되는 경우가 많습니다. 중간 체크포인트는 도메인 적응에 대한 가소성 및 수용성이 더 뛰어나기 때문입니다. 프로덕션 체크포인트는 광범위한 지침 준수 조정과 안전 훈련을 거칩니다. 이를 통해 일반적인 대화 사용에 맞게 모델을 최적화하지만 CPT 중에 새로운 도메인별 패턴을 학습하는 데 저항이 나타날 수도 있습니다. 반대로, 부분 및 완전히 사전 훈련된 텍스트 전용 체크포인트는 모델의 사전 훈련 특성을 유지합니다. 특정 동작에 지나치게 편향되지 않으므로 도메인 적응을 위한 보다 효율적인 시작점입니다. 대규모 CPT(10B 초과 토큰)를 수행할 때 중간 체크포인트부터 시작하면 일반적으로 수렴 속도가 빨라지고 훈련 안정성이 향상되며 도메인 지식 획득의 효율성이 개선됩니다. 그러나 소규모 CPT(10B 미만 토큰)의 경우 또는 지침 준수 기능을 유지해야 하는 경우 프로덕션 체크포인트가 더 적합할 수 있습니다. 모델의 대화형 기능을 유지 관리하면서 도메인 적응을 허용하기 때문입니다.

CPT에는 여러 중간 체크포인트가 필요합니다. 모델이 새로운 도메인 지식을 얼마나 효율적으로 흡수할 수 있는지에 영향을 미치는 여러 수준의 모델 가소성을 제공하기 때문입니다. 최종 프로덕션 체크포인트는 광범위한 지침 준수 조정과 안전 훈련을 거칩니다. 이를 통해 일반적인 대화 사용에 맞게 최적화하지만 새로운 도메인별 패턴을 학습하는 데 저항이 나타날 수도 있습니다. 즉, 사후 훈련을 통해 강화되었습니다. 반면 이전 체크포인트는 모델의 사전 훈련 특성을 유지하며 특정 동작에 크게 편향되지 않으므로 도메인 적응에 대한 가소성 및 수용성이 더 뛰어납니다.

최고의 훈련 효율성을 달성하기 위해 여러 중간 체크포인트가 제공됩니다.

어떤 체크포인트를 사용할 수 있나요?

Nova 2.0

3개의 Amazon Nova Lite 2.0 체크포인트가 있습니다.

- 사전 훈련 - [nova-lite-2/pretraining-text-RD]: 수조 단위의 토큰에서 모델을 훈련하는 Amazon Nova 사전 훈련의 일정한 학습 속도 및 감소 단계 이후 체크포인트입니다.
- 중간 훈련 - [nova-lite-2/pretraining-text-CE]: 이 체크포인트에서는 사전 훈련보다 더 보수적인 학습 속도로 중간 볼륨의 비정형 데이터를 도입하여 도메인별 지식을 흡수하는 동시에 파괴적 망각을 방지할 수 있습니다.
- 사후 훈련 - [nova-lite-2/prod]: 모든 관련 및 사후 훈련 단계를 거친 모델의 완전히 조정된 최종 체크포인트입니다.

다음 표에서는 사전 훈련 및 중간 훈련에 대한 여러 조건을 자세히 설명합니다.

데이터 형식	수행	체크포인트 사용
대규모 비정형 원시 도메인 데이터(문서, 로그, 문서, 코드 등)	지속적인 사전 훈련	사전 훈련
대규모 비정형 원시 도메인 데이터(문서, 로그, 문서, 코드 등)	중간 훈련	사전 훈련
더 작은 양의 비정형 원시 데이터. 정형 추론 트레이스/CoT 데이터	중간 훈련	중간 훈련

데이터 형식	수행	체크포인트 사용
비정형 데모(고품질 입력-출력 페어, 선별된 태스크 지침, 멀티 턴 대화)	전체 미세 조정	중간 훈련
비정형 데모(고품질 입력-출력 페어, 선별된 태스크 지침, 멀티 턴 대화)	파라미터 효율적 미세 조정	사후 훈련

사용할 체크포인트는 무엇인가요?

부분 사전 훈련된 텍스트 전용 체크포인트 및 완전히 사전 훈련된 텍스트 전용 체크포인트는 일반적으로 더 빠르게 수렴되며 도메인 적응을 위해 필요한 훈련 단계가 더 적습니다. 그러나 지침 조정이 없으며 유용한 태스크를 수행하고 지침을 따르려면 사후 훈련 단계를 거쳐야 합니다. GA 체크포인트를 조정하려면 적응하는 데 더 많은 단계가 필요하지만 소규모 실험을 위한 더 안전한 시작점을 제공하고 CPT 훈련 후에도 일부 사후 훈련 기능을 유지 관리할 수 있습니다.

일반적으로 큰 훈련 데이터세트(10B 초과 토큰)에서는 모델의 지식 베이스가 크게 수정되므로 보다 효율적이고 안정적인 훈련을 위해 부분 사전 훈련된 텍스트 전용 체크포인트 또는 완전히 사전 훈련된 텍스트 전용 체크포인트에서 시작합니다. 작은 데이터세트(10B 미만 토큰)에서는 GA 체크포인트를 사용하여 도메인에 적응하면서 지침 준수 기능을 유지합니다.

Nova 2.0에 대해 데이터 혼합을 사용하려면 어떻게 해야 하나요?

새 도메인 데이터로 CPT를 수행하는 경우 새 데이터를 모델의 사전 훈련 단계에서 이전에 사용한 일부 데이터와 혼합하는 것이 매우 유용합니다. 이전 데이터를 새 도메인 데이터와 혼합하면 다음과 같은 두 가지 문제가 해결됩니다.

- **망각 제어:** 모델의 기존 기술과 지식을 유지하여 파괴적 망각을 방지합니다. 데이터 혼합이 없으면 좁은 도메인 데이터에서만 훈련해 모델이 일반 기능을 덮어씁니다. 예를 들어, 법률 문서에서만 훈련된 모델은 코딩 또는 수학 기능을 상실할 수 있습니다. 일반 도메인 데이터세트를 혼합하면 새 도메인을 획득하는 동안 이러한 일반 기술을 유지할 수 있습니다.
- **최적화 안정성:** 모델의 내부 표현을 고정하여 훈련 안정성을 유지 관리합니다. CPT 중에 모델의 학습된 기능이 수정되고 데이터 혼합은 이러한 조정을 원활하게 안내하는 다양한 소스의 그라데이션을 제공합니다. 이 기능 없이 좁은 분포에서 훈련하면 그라데이션이 불안정해질 수 있습니다. 그러면 모델의 표현이 너무 급격하게 전환되어 훈련 분산, 손실 급증 또는 기존 기능의 축소가 나타날 수 있습니다.

습니다. 이는 안정성과 가소성의 상쇄 효과입니다. 모델은 새로운 도메인 지식을 학습할 수 있을 만큼 충분한 가소성을 갖추어야 하지만, 이미 알고 있는 지식을 파괴하지 않을 만큼 충분히 안정적이어야 합니다.

Nova CPT 데이터 혼합 기능

Amazon Nova 사전 훈련 데이터 및 체크포인트에 대한 액세스는 Amazon Nova CPT 사용자 지정의 핵심 오퍼링 중 하나입니다. Amazon Nova CPT 사용자 지정을 사용하면 도메인 데이터를 Amazon Nova의 사전 훈련 코퍼스와 쉽게 혼합할 수 있습니다. 또한 특정 Amazon Nova 데이터 범주(예: 코드, 수학, 추론 등)의 샘플링 비율을 변경하고 도메인 데이터를 보완하도록 해당 비율을 제어할 수 있습니다. 이를 통해 모델을 특정 도메인에 맞게 적응하면서 사용 사례에 맞는 기능을 강화할 수 있습니다.

최적의 혼합 비율 찾기

Amazon Nova 데이터 및 도메인 데이터의 최적 비율은 데이터세트의 도메인, 복잡성, 크기, 품질 및 일반적인 기능 유지 관리의 중요성에 따라 달라집니다. 이 비율은 실험을 통해 찾아야 합니다. 혼합할 Amazon Nova 데이터의 양을 결정하는 실험 프레임워크는 다음과 같습니다.

도메인 데이터의 대표적인 하위 세트(예: 5B 토큰)를 선택하고 모든 실험 실행에서 이를 일정하게 유지합니다.

다음과 같이 혼합된 Amazon Nova 데이터의 양만 달라지는 소규모 CPT 실험을 실행합니다.

- 혼합 없음: 100% 도메인 → 5B 도메인만(총 5B)
- 가벼운 혼합: 90% 도메인 → 5B 도메인 + ~0.56B Amazon Nova(총 ~5.56B)
- 중간 혼합: 70% 도메인 → 5B 도메인 + ~2.14B Amazon Nova(총 ~7.14B)
- 과중한 혼합: 50% 도메인 → 5B 도메인 + 5B Amazon Nova(총 10B)

도메인 및 일반 도메인 벤치마크에서 각 체크포인트를 평가합니다. 또한 시작 체크포인트(훈련 전 Amazon Nova 체크포인트)를 평가합니다.

- 고객 도메인 성능이 여러 실행에서 대략적으로 일정하게 유지되나요? 각 실행에서 동일한 수의 도메인 토큰이 보이므로 일반적으로 그렇습니다. 많은 혼합에서 도메인 성능이 향상되면 Amazon Nova 데이터는 유용한 정규화를 제공합니다.
- 혼합이 증가하면 일반 벤치마크 점수가 개선되나요?
 - Amazon Nova 데이터가 더 추가되면 일반적인 기능은 단조롭게 개선되는 것이 예상되는 동작입니다.

- MMLU(일반 지식), HumanEval(코딩), GSM8K(수학) 또는 특정 관심 벤치마크 등 여러 일반 벤치마크를 측정합니다.
- 사용 사례에 적합한 일반 기능을 제공하면서 도메인 성능을 유지 관리하는 혼합 비율을 선택합니다. 많은 데이터 혼합을 사용하는 추가 훈련 비용을 고려합니다.

최적의 혼합 비율이 식별되면 선택한 혼합 비율로 전체 도메인 데이터세트를 사용하여 전체 규모 CPT를 실행합니다.

데이터 혼합 범주 분석

아래에서는 데이터 혼합에서 사용 가능한 각 범주를 분석합니다. 이를 기반으로 전체 데이터 혼합에서 가장 적합한 데이터 범주에 대한 최선의 결정을 내릴 수 있습니다.

데이터 혼합을 활성화하는 방법

여러 데이터세트 범주에서 적절한 백분율 분포를 사용하여 레시피에 `data_mixing` 섹션을 추가합니다. `nova_data` 백분율의 합계는 100이어야 합니다.

데이터 혼합을 사용하는 Nova 2.0 구성

```
# 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
```

이러한 범주의 의미

참고: Nova 2.0에는 Nova 1.0에서 사용할 수 없는 추가적인 추론별 범주(예: reasoning-code, reasoning-math, reasoning-instruction-following)가 포함되어 있습니다.

범주 및 정보 레이블 요약:

범주 이름	세부 정보
agents	AI 시스템의 자율 의사 결정, 태스크 완료 및 목표 지향적 동작에 초점을 맞춘 훈련 데이터
baseline	일반적인 이해, 기본 커뮤니케이션 및 핵심 언어 기능에 초점을 맞춘 기초적인 언어 데이터
chat	자연스러운 대화 흐름, 컨텍스트 유지 관리 및 적절한 사회적 상호 작용을 보여주는 대화식 교환
code	다양한 프로그래밍 언어 및 플랫폼의 프로그래밍 소스 코드, 설명서 및 기술 토론
factuality	정확성, 소스 검증 및 사실 평가에 초점을 둔 참조 자료 및 확인된 정보
identity	일관된 캐릭터 특성, 가치 및 상호 작용 스타일에 초점을 둔 성격 프레임워크 및 행동 패턴

범주 이름	세부 정보
long-context	여러 긴 교환에서 일관성과 관련성을 유지 관리하는 데 초점을 둔 확장된 텍스트 및 복잡한 서술
math	교과서, 문제, 솔루션, 수학적 토론을 포함한 수학 콘텐츠
rai	윤리적 AI 원칙, 안전 고려 사항 및 책임 있는 기술 배포를 강조하는 사례 및 시나리오
instruction-following	다양한 수준의 사용자 프롬프트 및 지침에 기반한 정확한 태스크 실행 예제
stem	문제 해결 및 이론적 개념을 포함하여 과학, 기술, 엔지니어링 및 수학을 다루는 기술 콘텐츠
planning	전략적 사고, 단계별 태스크 분석 및 효율적인 리소스 할당을 보여주는 시퀀스
reasoning-chat	논리적 토론 및 구조화된 대화 흐름에 초점을 둔 분석 대화 시나리오
reasoning-code	체계적인 솔루션 개발에 초점을 둔 프로그래밍 문제 및 알고리즘 문제
reasoning-factuality	중요한 평가 및 확인 프로세스에 초점을 둔 정보 평가 시나리오
reasoning-instruction-following	체계적인 해석 및 실행에 초점을 둔 복잡한 태스크 분석
reasoning-math	논리적 진행 및 솔루션 전략에 초점을 둔 수학적 문제 해결 시나리오
reasoning-planning	목표 달성에 대한 체계적인 접근 방식에 초점을 둔 전략적 의사 결정 시나리오
reasoning-rag	컨텍스트 이해 및 관련 애플리케이션에 초점을 둔 정보 검색 및 가상 시나리오
reasoning-rai	AI 안전 및 공정성에 대한 체계적인 평가에 초점을 둔 윤리적 의사 결정 시나리오

범주 이름	세부 정보
reasoning-stem	체계적인 분석 및 솔루션 개발에 초점을 둔 과학적 문제 해결 시나리오
rag	검색된 외부 지식을 생성된 응답과 효과적으로 결합하여 상황에 맞는 정확한 정보를 제공하는 예제
translation	컨텍스트, 어조 및 문화적 뉘앙스를 유지하면서 정확한 번역을 보여주는 다국어 콘텐츠 페어

파라미터 가이드

- `dataset_catalog`: 멀티모달 훈련을 활성화할 때까지 현재 유일한 값은 `cpt_text_lite`입니다.
- `nova_data`: 혼합 시 Nova 데이터의 개별 범주 백분율. 최대 합계는 1.0입니다.
- `customer_data`: Nova 데이터에 혼합된 고객 데이터의 백분율.

훈련에 사용된 총 토큰 수는 $\text{max\_length} * \text{global\_batch\_size} * \text{max\_steps}$ 공식에서 계산할 수 있습니다.

제한 사항

현재 CPT는 텍스트 데이터만 지원하며 고객 멀티모달 데이터세트를 지원하지 않습니다.

지도 미세 조정

소개

지도 미세 조정은 관심 태스크에 입력-출력 페어가 있는 데이터세트를 사용합니다. 즉, 올바른 응답이나 원하는 응답과 함께 프롬프트의 예제(질문, 지침 등)를 제공하고 이를 기반으로 모델을 계속 훈련합니다. 모델의 가중치는 지도 손실, 일반적으로 예측과 대상 응답 토큰 간 교차 엔트로피를 최소화하도록 조정됩니다.

SFT는 언제 사용하나요?

SFT는 원하는 출력이 명확한 잘 정의된 태스크가 있는 경우에 가장 적합합니다. 'X 입력 제공, 올바른 출력/원하는 출력은 Y'라고 명시적으로 말할 수 있고 이러한 X-Y 매핑의 예제를 수집할 수 있는 경우 지도 미세 조정이 가장 적합합니다. SFT가 탁월한 일부 시나리오는 다음과 같습니다.

- 구조화되거나 복잡한 분류 태스크: 예를 들어 내부 문서 또는 계약을 여러 사용자 지정 범주로 분류. SFT를 사용하면 모델은 프롬프트만 사용할 때보다 이러한 특정 범주를 훨씬 더 잘 학습할 수 있습니다.
- 알려진 답변이 있는 질문 답변 또는 변환 태스크: 예를 들어 회사의 지식 베이스를 통해 질문에 답변하거나 각 입력에 올바른 응답이 있는 경우 여러 형식 사이에서 데이터를 변환하도록 모델 미세 조정.
- 형식 지정 및 스타일 일관성: 모델이 항상 특정 형식 또는 어조로 응답해야 하는 경우 올바른 형식/어조의 예제를 미세 조정할 수 있습니다. 예를 들어 특정 브랜드 음성 또는 스타일을 보여주는 프롬프트-응답 페어를 훈련하는 경우 출력에서 해당 스타일로 모델을 학습시킬 수 있습니다. 지침 준수 동작은 종종 처음에 SFT를 통해 선별된 올바른 어시스턴트 동작 예제를 통해 학습됩니다.

SFT는 올바른 동작을 지정할 수 있는 경우 LLM에 새로운 기술이나 동작을 가르치는 가장 직접적인 방법입니다. 그리고 모델의 기존 언어 이해를 활용하고 태스크에 집중합니다. 동작이 아닌 지식에서 격차가 있는 경우 SFT를 사용하지 마세요. 모델은 새로운 사실, 전문 용어 또는 최근 이벤트를 학습하지는 않습니다. 이 경우 추론 시 외부 지식을 제공하기 위해 대규모 도메인 내 코포라 또는 검색 증강 생성에 대한 지속적인 사전 훈련이 선호됩니다. 품질을 측정할 수 있지만 하나의 올바른 답변에 레이블을 지정할 수 없는 경우 SFT보다 검증 가능한 보상 또는 평가형 LLM을 사용한 강화 미세 조정이 더 선호될 수 있습니다.

조정 없이 Nova 모델의 태스크 복잡성과 성능에 따라 원시 볼륨보다 더 중요한 데이터 품질, 일관성 및 다양성을 고려하여 태스크당 수천에서 수만 개의 데모를 계획합니다.

언제 파라미터 효율적 미세 조정을 사용하고, 언제 전체 순위 SFT를 사용해야 하나요?

Nova 사용자 지정 레시피를 사용하면 파라미터 효율적 미세 조정, 특히 LoRA 또는 전체 순위 SFT를 수행할 수 있습니다. 간단하고 비용 효율적인 모델 업데이트를 원하거나 데이터가 거의 없는 경우 대부분의 백본을 그대로 유지하면서 소형 어댑터를 훈련할 수 있도록 파라미터 효율적 미세 조정 방법을 선호합니다(전체 순위 SFT는 모든 모델 파라미터를 업데이트함).

SFT에 대한 데이터 혼합

데이터 혼합을 사용하면 사용자 지정 훈련 데이터셋을 Nova의 독점 훈련 데이터와 결합할 수 있습니다. 이 기능은 Nova 1.0 및 Nova 2.0 모델 모두에서 사용할 수 있습니다.

Nova 독점 데이터 유형: Nova는 텍스트 및 멀티모달 SFT 데이터 유형을 모두 지원합니다. 각각 해당 범주와 관련된 태스크 혼합을 포함하는 여러 데이터 범주로 구성됩니다.

Nova 독점 데이터 범주: 이 텍스트 데이터세트에는 자율 의사 결정, 태스크 완료, 목표 중심 데이터세트(에이전트), 추론 및 비추론과 관련된 정확한 태스크 실행 데이터세트(추론 지침 준수, 지침 준수), 전략적 사고 및 단계별 태스크 분류를 보여주는 시퀀스(계획), 책임 있는 AI(rai), 긴 컨텍스트, 사실성, 수학, 어간 등을 비롯한 여러 범주가 포함됩니다. 마찬가지로 멀티모달 데이터세트에는 비디오, 스크린샷, 차트 등이 포함됩니다.

데이터 혼합 기능을 사용하면 자체 미세 조정 훈련 샘플을 Nova를 미세 조정하는 데 사용되는 Nova 데이터세트의 샘플과 혼합할 수 있습니다. 이를 통해 사용자 지정 훈련의 과적합과 Nova 기능의 '파괴적 망각'을 방지하거나 사전 훈련된 새 체크포인트에서 훈련할 때 기능을 빌드하는 데 도움이 될 수 있습니다.

Nova 데이터를 혼합하려면 training_config 섹션 아래에서 레시피 YAML 파일에 data_mixing 블록을 추가하기만 하면 됩니다. 텍스트 및 멀티모달 데이터 혼합 블록에서 콘텐츠는 서로 다릅니다. 해당 레시피를 참조하세요.

지원되는 모델

- Nova 2.0 Lite

지원되는 모달리티

- 텍스트
- 멀티모달

YAML 구성 예제

Nova 2.0 구성 예제

```
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
```

Nova 2.0 텍스트 데이터 혼합

```
data_mixing:
  dataset_catalog: sft_1p5_text_chat
  sources:
    customer_data:
      percent: 50
    nova_data:
      agents: 1
      baseline: 10
      chat: 0.5
      code: 10
      factuality: 0.1
      identity: 1
      long-context: 1
      math: 2
      rai: 1
      instruction-following: 13
      stem: 0.5
      planning: 10
```

```
reasoning-chat: 0.5
reasoning-code: 0.5
reasoning-factuality: 0.5
reasoning-instruction-following: 45
reasoning-math: 0.5
reasoning-planning: 0.5
reasoning-rag: 0.4
reasoning-rai: 0.5
reasoning-stem: 0.4
rag: 1
translation: 0.1
```

Nova 2.0 멀티모달 데이터 혼합

```
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
```

모델 체크포인트

Nova 2.0 체크포인트

- 사전 훈련[nova-lite-2/pretraining-text-RD]: 수조 단위의 토큰에서 모델을 훈련하는 일정한 학습 속도 및 감소 단계 이후 체크포인트. [2단계 결과]

- 중간 훈련[nova-lite-2/pretraining-text-CE]: 중간 볼륨의 비정형 데이터를 사용하는 고객이 사전 훈련보다 더 보수적인 학습 속도로 데이터를 도입하여 도메인별 지식을 흡수하는 동시에 파괴적 망각을 방지할 수 있습니다. [3단계 결과]
- 최종[nova-lite-2/prod]: 모든 사전 훈련 및 사후 훈련 단계를 거친 완전히 조정된 최종 체크포인트. [4단계 결과]

훈련 단계:

- 1단계: PT Ckpt, 일정한 학습 속도의 초기 사전 훈련
- 2단계: PT Ckpt, 학습 속도 감소
- 3단계: PT Ckpt, 컨텍스트 확장 훈련
- 4단계: 지침 준수 조정 및 안전 교육

훈련 접근 방식

훈련 접근 방식 선택 가이드

데이터 형식	데이터 볼륨	수행	체크포인트 사용
대규모 비정형 원시 도메인 데이터(문서, 로그, 문서, 코드 등)	1T 이상의 토큰	지속적인 사전 훈련	일정한 학습 속도(CLR) 종료
대규모 비정형 원시 도메인 데이터	100B 이상의 토큰	중간 훈련	CLR 종료
더 작은 양의 비정형 원시 데이터, 정형 추론 트레이스/CoT 데이터	1B 이상의 토큰	중간 훈련	Nova 기본 모델
비정형 데모(고품질 입력-출력 페어, 선별된 태스크 지침, 멀티턴 대화)	1K 이상의 예제	지도 미세 조정(SFT)	Nova 기본 모델

시작하기 전 사전 조건

- 이 경우 활성 용량이 있는 제한된 인스턴스 그룹(RIG)으로 SMHP 클러스터를 이미 설정했다고 가정합니다. 그렇지 않으면 여기를 참조하여 SMHP 클러스터 및 RIG 설정을 완료하세요. [[문서 링크](#), [위크숍 링크](#)]
- 이 레시피를 실행하려면 p5.48xlarge EC2 인스턴스가 필요합니다. 이 레시피를 효율적으로 실행하는 데 필요한 최소 인스턴스 수는 다음과 같습니다.
 - Nova Lite 2.0 - 4 p5.48xlarge
- [여기](#)에 제공된 지침을 사용하여 Forge 특정 SageMaker HyperPod CLI 설치
- hyperpod get-clusters를 사용하여 클러스터에 연결할 수 있는지 확인
 - 이 명령은 계정의 모든 SMHP 클러스터를 나열함
- SMHP 클러스터의 실행 역할이 액세스할 수 있는 S3 버킷에서 훈련 및 검증 데이터(선택 사항)를 사용할 수 있는지 확인합니다. 데이터 준비는 다음 섹션을 참조하세요.
- 설정을 완료합니다. 설정을 완료하지 않은 경우 아래 [가이드](#)를 따르세요.
- 확인: 설정을 완료한 후 아래 명령을 성공적으로 실행할 수 있는지 확인

```
aws sagemaker describe-cluster --cluster-name <cluster-name> --region <region>

hyperpod connect-cluster --cluster-name cluster-name
```

성공적인 SFT를 달성하기 위한 체계적인 접근 방식

- 데이터 준비: 정해진 지침에 따라 데이터셋을 생성, 정리 또는 필요한 구조로 다시 포맷합니다. 입력, 출력 및 보조 정보(예: 추론 트레이스 또는 메타데이터)가 올바르게 조정되고 형식이 지정되었는지 확인합니다.
- 훈련 구성: 모델 훈련 방법을 정의합니다. Amazon SageMaker HyperPod를 사용하는 경우 이 구성은 다음을 포함하는 YAML 레시피 파일로 작성됩니다.
 - 데이터 소스 경로(훈련 및 검증 데이터셋)
 - 주요 하이퍼파라미터(훈련 단계 수, 학습 속도, 배치 크기)
 - 선택적 구성 요소(분산 훈련 파라미터 등)
 - 데이터 혼합 설정(고객 및 Nova 데이터 범주의 비율 정의)

- SFT 하이퍼파라미터 최적화: 권장하는 SFT 레시피 파라미터 값은 훌륭한 출발점이며 강력한 선택 지입니다. 사용 사례에 맞게 더 최적화하려면 다양한 파라미터 조합으로 여러 SFT 실행을 수행하고 가장 적합한 항목을 선택합니다. 선택한 하이퍼파라미터 최적화 방법에 따라 파라미터 조합을 선택할 수 있습니다. 단순한 접근 방식은 다른 파라미터에 대한 다른 기본값을 유지하면서 한 파라미터의 값(기본값*0.5, 기본값, 기본값*2)을 변경한 다음, 최적화하려는 각 파라미터에 대해 이 작업을 다시 수행하고, 필요한 경우 이를 반복하는 것입니다. LoRA에 대해 가장 관련성이 높은 파라미터는 학습 속도, 알파(스케일링 파라미터), 훈련할 에포크 수 및 워밍업 단계입니다. 전체 순위의 경우 주로 학습 속도, 에포크 수 및 워밍업 단계입니다.

실험 시퀀싱 및 데이터 혼합

- 태스크 세트에 대한 SFT 데이터(train/dev/test)만 있고 이러한 태스크에서 테스트 성능에만 주의를 기울이는 경우
 - [최종] Nova 체크포인트에서 혼합하지 않고 SFT를 수행합니다. 기본 SFT 하이퍼파라미터를 사용하고 선택적으로 사용 사례에 맞게 최적화합니다. 검증 지표를 모니터링하고 또는 더 큰 데이터 세트에 대한 중간 체크포인트를 평가합니다.
- 태스크 세트에 대한 SFT 데이터(train/dev/test)만 있고 이러한 태스크에서 테스트 성능 및 관심 도메인의 일반 벤치마크에 주의를 기울이는 경우
 - 먼저 사전 훈련 체크포인트(사전 훈련 또는 중간 훈련 체크포인트에 해당하며, 최종 체크포인트가 아님)에서 Nova 데이터 혼합으로 SFT를 수행합니다. 중간 체크포인트를 사용하면 모델이 강력한 일반 기능을 유지 관리하면서 사용자 지정 데이터를 Nova의 독점 데이터와 더 잘 통합할 수 있습니다.
 - 혼합에서 Nova 데이터의 양(예: 10%, 25%, 50%, 75%)을 달리하고 사용 사례를 보완하는 Nova 데이터 범주(예: 일반 지침 준수 기능에 관심이 있는 경우 지침 준수 범주 선택)를 선택하여 더 짧은 SFT 훈련 실행을 수행합니다. 검증 지표를 모니터링하고 혼합이 일반 벤치마크의 성능에 도움이 되는지 평가합니다. 태스크 성능 및 일반 성능에서 최상의 조합을 구성하는 훈련 혼합 및 체크포인트를 선택합니다. 사용 사례에 따라 강화 미세 조정(RFT)을 사용하여 태스크 및 일반 성능을 더욱 개선할 수 있습니다.

SFT에 대한 데이터세트 준비

Nova 2.0: Converse API 형식을 사용합니다(<https://docs.aws.amazon.com/bedrock/latest/userguide/conversation-inference-call.html>). Nova 2.0 데이터 형식에는 추가 추론 필드가 포함될 수 있습니다(https://docs.aws.amazon.com/bedrock/latest/APIReference/API_runtime_ReasoningContentBlock.html).

추론 콘텐츠는 최종 답변을 생성하기 전에 모델의 중간 사고 단계를 캡처합니다. assistant 턴에서 reasoningContent 필드를 사용하여 추론 트레이스를 포함합니다. 추론 콘텐츠에 일반 텍스트를 사용하고, 태스크에 특별히 필요하지 않은 한 <thinking> 및 </thinking>과 같은 마크업 태그를 피하며, 추론 콘텐츠가 명확하고 문제 해결 프로세스와 관련이 있는지 확인합니다.

평가 지표

사전 조건

- 훈련 작업 manifest.json 파일의 체크포인트 S3 URI(훈련된 모델의 경우)
- 올바른 형식으로 S3에 업로드된 평가 데이터세트
- 평가 결과에 대한 출력 S3 경로

즉시 사용 가능한 벤치마크: 즉시 사용 가능한 벤치마크를 통해 일반 태스크의 성능을 검증합니다. 자세한 내용은 <https://docs.aws.amazon.com/sagemaker/latest/dg/nova-hp-evaluate.html>을 확인하세요.

자체 데이터 사용

또한 아래 형식으로 지정한 다음 아래에 언급된 컨테이너를 사용하여 필요한 경우 보정에 대한 로그 확률과 함께 추론 결과를 가져와 사용자 지정 데이터를 제공할 수 있습니다.

다음 구조를 사용하여 태스크당 jsonl을 생성합니다.

```
{
  "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"
}
```

평가 작업의 추론 단계 중에 생성된 출력의 구조는 다음과 같습니다.

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

필드 설명:

- **prompt**: 모델로 전송된 형식 지정된 입력
- **inference**: 모델의 생성된 응답
- **gold**: 입력 데이터세트의 예상되는 정답, 입력의 응답 필드
- **metadata**: 입력에서 전달되는 선택적 메타데이터

평가 구성 준비

평가 작업을 시작하는 명령. 레시피에서 항목을 수정하려면 "--override-parameters"를 사용합니다.

```
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"
  }'
```

모범 사례

- **볼륨보다 데이터 품질 우선**: 고품질의 다양한 대표 훈련 데이터는 대량의 저품질 데이터보다 더 유용합니다.
- **추론 지침 준수 범주 포함**: 데이터 혼합을 사용하는 경우 '추론 지침 준수' 범주를 포함하여 태스크 전반에서 강력한 일반 성능을 유지 관리합니다.
- **기본 학습 속도 사용**: 기본 학습 속도(LoRA의 경우 1e-5, 전체 순위 SFT의 경우 5e-6)로 시작하고 검증 지표에 따라 필요한 경우에만 조정합니다.

- Nova 데이터 혼합 균형 조정: 최적의 지연 시간과 성능 균형을 위해 최대 50% Nova 데이터를 혼합합니다. 비율이 높을수록 일반적인 기능이 향상될 수 있지만 훈련 시간이 늘어날 수 있습니다.
- 검증 지표 모니터링: 훈련 중에 중간 체크포인트를 정기적으로 평가하여 과적합 또는 성능 저하를 조기에 감지합니다.
- 대표 데이터세트에서 테스트: 평가 데이터세트가 의미 있는 성능 평가를 위한 프로덕션 사용 사례를 정확하게 대표하도록 보장합니다.

훈련 작업 구성 준비

하이퍼 파라미터

데이터 혼합 이외의 전체 하이퍼파라미터 세트:

```
## 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)

```

LoRA에 대해 가장 관련성이 높은 파라미터는 학습 속도, 알파(스케일링 파라미터), 훈련할 에포크 수 및 워밍업 단계입니다. 전체 순위의 경우 주로 학습 속도, 에포크 수 및 워밍업 단계입니다. 레시피는 권장되는 기본값으로 미리 채워집니다.

데이터 혼합 블록 설정

여러 데이터세트 범주에서 적절한 백분율 분포를 사용하여 레시피에 data_mixing 섹션을 추가합니다.

아래에서는 사용 가능한 각 Nova 데이터 범주를 설명합니다.

데이터 혼합을 사용하는 Nova 2.0 구성

```

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

```

이러한 범주는 무엇을 의미하나요?

Nova 2.0 텍스트 데이터 범주

범주 이름	세부 정보
에이전트	AI 시스템의 자율 의사 결정, 태스크 완료 및 목표 지향적 동작에 초점을 맞춘 훈련 데이터
기준	일반적인 이해, 기본 커뮤니케이션 및 핵심 언어 기능에 초점을 맞춘 기초적인 언어 데이터
chat	자연스러운 대화 흐름, 컨텍스트 유지 관리 및 적절한 사회적 상호 작용을 보여주는 대화식 교환
code	다양한 프로그래밍 언어 및 플랫폼의 프로그래밍 소스 코드, 설명서 및 기술 토론
factuality	정확성, 소스 검증 및 사실 평가에 초점을 둔 참조 자료 및 확인된 정보
identity	일관된 캐릭터 특성, 가치 및 상호 작용 스타일에 초점을 둔 성격 프레임워크 및 행동 패턴
long-context	여러 긴 교환에서 일관성과 관련성을 유지 관리하는 데 초점을 둔 확장된 텍스트 및 복잡한 서술
math	교과서, 문제, 솔루션, 수학적 토론을 포함한 수학 콘텐츠
rai	윤리적 AI 원칙, 안전 고려 사항 및 책임 있는 기술 배포를 강조하는 사례 및 시나리오
instruction-following	다양한 수준의 사용자 프롬프트 및 지침에 기반한 정확한 태스크 실행 예제
어간	문제 해결 및 이론적 개념을 포함하여 과학, 기술, 엔지니어링 및 수학을 다루는 기술 콘텐츠

범주 이름	세부 정보
계획	전략적 사고, 단계별 태스크 분석 및 효율적인 리소스 할당을 보여주는 시퀀스
reasoning-chat	논리적 토론 및 구조화된 대화 흐름에 초점을 둔 분석 대화 시나리오
reasoning-code	체계적인 솔루션 개발에 초점을 둔 프로그래밍 문제 및 알고리즘 문제
reasoning-factuality	중요한 평가 및 확인 프로세스에 초점을 둔 정보 평가 시나리오
reasoning-instruction-following	체계적인 해석 및 실행에 초점을 둔 복잡한 태스크 분석
reasoning-math	논리적 진행 및 솔루션 전략에 초점을 둔 수학적 문제 해결 시나리오
reasoning-planning	목표 달성에 대한 체계적인 접근 방식에 초점을 둔 전략적 의사 결정 시나리오
reasoning-rag	컨텍스트 이해 및 관련 애플리케이션에 초점을 둔 정보 검색 및 가상 시나리오
reasoning-rai	AI 안전 및 공정성에 대한 체계적인 평가에 초점을 둔 윤리적 의사 결정 시나리오
reasoning-stem	체계적인 분석 및 솔루션 개발에 초점을 둔 과학적 문제 해결 시나리오
rag	검색된 외부 지식을 생성된 응답과 효과적으로 결합하여 상황에 맞는 정확한 정보를 제공하는 예제
변환	컨텍스트, 어조 및 문화적 뉘앙스를 유지하면서 정확한 번역을 보여주는 다국어 콘텐츠 페어

멀티모달 데이터 혼합(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
```

참고: Nova 2.0에는 Nova 1.0에서 사용할 수 없는 비디오 데이터 범주 지원이 포함되어 있습니다.

이러한 범주는 무엇을 의미하나요?

Nova 2.0 멀티모달 데이터 범주

범주 이름	세부 정보
차트	모델이 정량적 정보를 효과적으로 이해하고 전달하는 데 도움이 되는 그래프, 파이 차트, 막대 차트, 선형 플롯 및 기타 통계 시각화의 시각적 표현 및 설명
chat	컨텍스트 기반 대화 이해 및 이미지 기반 상호 작용에 초점을 둔 시각적 요소와 페어를 이루는 대화 데이터

범주 이름	세부 정보
code	시각적 코드 해석, IDE 스크린샷 및 기술 다이어그램에 초점을 둔 프로그래밍 인터페이스 및 개발 환경
docs	PDF 콘텐츠 인식과 같은 개념에 도움이 되도록 다양한 문서 유형 및 구조를 이해하고 처리하는 모델을 훈련하기 위해 텍스트, 이미지, 레이아웃 및 형식을 결합한 문서 중심 데이터
일반	이미지, 그래픽 및 수반되는 설명 텍스트의 광범위한 이해에 초점을 둔 다양한 시각적-텍스트 콘텐츠
그라운드	언어 개념을 실제 시각적 표현에 연결하는 데 초점을 둔 시각적 참조 자료 및 레이블이 지정된 이미지
rag	시각적 및 텍스트 외부 지식을 효과적으로 결합하고 참조하여 정확한 컨텍스트 기반 응답을 생성하는 방법을 보여주는 멀티모달 검색 예제
screenshot	소프트웨어 인터페이스 및 디지털 상호 작용을 이해하는 데 초점을 둔 애플리케이션 인터페이스 캡처 및 디지털 표시 이미지
텍스트	일반론적 기능을 제공하기 위해 텍스트 전용 SFT Nova 데이터세트 범주에서 생성된 컨텍스트 기반 텍스트 데이터의 균형 잡힌 풀
변환	이미지 및 문화적 시각적 요소 내 텍스트의 다국어 해석에 초점을 둔 교차 언어 시각적 콘텐츠
비디오	시간적 이해와 순차적인 시각적 서술 이해에 초점을 둔 모션 기반 시각적 콘텐츠

작업을 시작하는 방법

첫 번째 SFT 실행을 시작하는 데 필요한 핵심 세부 정보만 가져오는 경우 README를 참조할 수도 있습니다.

컨테이너 정보:

컨테이너 정보 및 시작 명령

모델	기술	Subcategory	이미지 URI	Hyperpod 런처 명령
Nova 2.0	미세 조정	SFT 텍스트	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-SFT-V2-latest	hyperpod start-job \ -n kubeflow \ --recipe fine-tuning/nova/nova_2_0/nova_lite/SFT/nova_lite_2_0_p5_gpu_sft \ --override-parameters '{ "instance_type": "ml.p5.48xlarge", "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-SFT-V2-latest" }'
Nova 2.0	미세 조정	SFT 텍스트 + 데이터 혼합	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-	hyperpod start-job \ -n kubeflow \ --recipe fine-tuning/nova/forge/nova_2_0/nova_lite/

모델	기술	Subcategory	이미지 URI	Hyperpod 런처 명령
			SFT-V2-DAT AMIXING-latest	SFT/nova_lite_2_0_p5_gpu_sft_t ext_with_datamix \ --override- parameters { "instance _type": "ml.p5.48 xlarge", "container": "70897720 5387.dkr.ecr.us- east-1.amaz onaws.com/ nova-fine-tune- repo:SM-HP- SFT-V2-DA TAMIXING- latest" }

모델	기술	Subcategory	이미지 URI	Hyperpod 런처 명령
Nova 2.0	미세 조정	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" }'

모델	기술	Subcategory	이미지 URI	Hyperpod 런처 명령
Nova 2.0	미세 조정	SFT MM + 데이터 혼합	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" }'

설정이 모두 완료되면 sagemaker-hyperpod-cli 리포지토리의 루트에서 시작하여 기본 nova sft 레시피 폴더로 이동합니다.

- cd /src/hyperpod_cli/sagemaker_hyperpod_recipes/recipes_collection/recipes/training/nova/
- 여기서 기본 모델 선택에 따라 nova 1 또는 nova 2 레시피를 실행할지를 선택할 수 있습니다.

Nova 2.0 sft의 경우:

- 일반 sft 작업을 사용하려면 이 폴더에서 레시피 하나를 볼 수 있어야 함
 - `cd /src/hyperpod_cli/sagemaker_hyperpod_recipes/recipes_collection/recipes/fine-tuning/nova_2_0/nova_lite/SFT` and then you should be able to see one recipe under this folder called `nova_lite_2_0_p5x8_gpu_sft.yaml`
- 데이터 혼합 sft 작업을 사용하려면 sft Forge 레시피 폴더로 이동할 수 있음
 - `cd /src/hyperpod_cli/sagemaker_hyperpod_recipes/recipes_collection/recipes/fine-tuning/nova_forge/nova_2_0/nova_lite/SFT` and you should be able to see one recipe under this folder called: `nova_lite_2_0_p5x8_gpu_sft_with_datamix.yaml`
- `name`, `data_s3_path`, `validation_s3_path`, `output_s3_path`, `max_steps`와 같이 작업에 필요한 레시피의 섹션을 편집합니다. sft를 수행하므로 여기에 epoch 개념은 적용되지 않습니다.

데이터 혼합 구성이 동일하게 보이지만 하단에 이와 비슷한 추가 데이터 혼합 섹션이 있습니다.

```
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
```

여기에는 두 가지 최상위 데이터 범주가 있습니다.

- nova_data : 실제 데이터 혼합이며 더 많은 범주로 세분화됩니다. 100%까지 합산해야 합니다.
 - 토큰 수를 포함한 이러한 범주의 전체 분석은 아래에서 확인할 수 있음
- customer_data : yaml 상단의 data_s3_path 키에서 참조되는 훈련 데이터입니다. 여기에 제공된 백분율은 nova_data에 대한 결과 백분율을 결정합니다. 예를 들어 위의 백분율 선택에서 훈련 중에 customer_data로 25%, nova_data로 75%(이때 15%는 agents, 15%는 business-and-finance, 15%는 scientific, 15%는 code, 15%는 factual-and-news)를 사용함

팁: pip install -e를 다시 한 번 실행합니다. 그러면 작업을 제출할 준비가 됩니다!

여기서는 데이터 혼합을 사용하기 위해 몇 가지 파라미터를 재정의합니다.

```
hyperpod start-job \
  -n kubeflow \
  --recipe fine-tuning/nova/forg/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/
  }'
```

출력에는 다음과 같은 작업 이름이 포함됩니다.

```
# MY Desktop # % hyperpod start-job \
  -n kubeflow \
  --recipe training/nova/forg/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": "3://sft-data/sft_val_data.jsonl",
    "recipes.run.output_s3_path": "3://sft-data/output/
```

```
}'
```

출력은 다음과 같습니다.

```
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"
}
```

hyperpod list-pods -n kubeflow --job-name my-sft-run-wzdyn을 사용하여 작업 상태를 볼 수 있습니다.

```
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"
  }
]
}

```

또는 `kubectl` 명령을 직접 사용하여 찾습니다.

예:

```
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>

전문가 팁: 작업이 실행되는 EKS 노드는 AWS UI에서 로그를 더 빨리 찾는 데 도움이 되므로 항상 `-o wide` 플래그를 사용해야 합니다.

작업을 모니터링하는 방법

다음과 같은 세 가지 방법 중 하나로 로그를 볼 수 있습니다.

a) CloudWatch 사용

로그는 CloudWatch 아래의 하이퍼포드 클러스터를 포함하는 Amazon Web Services 계정에서 사용할 수 있습니다. 브라우저에서 보려면 계정의 CloudWatch 홈페이지로 이동하여 클러스터 이름을 검색합

니다. 예를 들어 my-hyperpod-rig라고 하는 클러스터가 있으면 로그 그룹에 다음과 같은 접두사가 붙습니다.

- 로그 그룹: /aws/sagemaker/Clusters/my-hyperpod-rig/{UUID}
- 로그 그룹에 있으면 - hyperpod-i-00b3d8a1bf25714e4와 같은 노드 인스턴스 ID를 사용하여 특정 로그를 찾을 수 있습니다.
 - 여기서, i-00b3d8a1bf25714e4는 훈련 작업이 실행 중인 Hyperpod 친화적인 시스템 이름을 나타냅니다. 이전 명령 `kubectl get pods -o wide -w -n kubeflow | (head -n1 ; grep my-cpt-run)` 출력에서 NODE 열을 캡처한 방법을 떠올려 보세요.
 - 이 경우에 '마스터' 노드 실행은 hyperpod-i-00b3d8a1bf25714e4에서 실행되었으므로 해당 문자열을 사용하여 보려는 로그 그룹을 선택합니다. SagemakerHyperPodTrainingJob/rig-group/[NODE]라고 표시된 항목을 선택합니다.

로그는 다음과 같아야 합니다.

b) CloudWatch Insights 사용

작업 이름이 유용하고 위의 모든 단계를 진행하지 않으려는 경우 /aws/sagemaker/Clusters/my-hyperpod-rig/{UUID}에서 모든 로그를 쿼리하여 개별 로그를 찾을 수 있습니다.

CPT

```
fields @timestamp, @message, @logStream, @log
| filter @message like /(?!i)Starting CPT Job/
| sort @timestamp desc
| limit 100
```

작업 완료 시 Starting SFT Job을 SFT Job completed로 바꾸기

그런 다음 결과를 클릭하고 'Epoch 0'이라고 표시된 결과를 선택할 수 있습니다. 마스터 노드가 되기 때 문입니다.

c) aws cli 사용

다음을 사용하여 로그를 테일링하도록 선택할 수 있습니다. 이렇게 하기 전에 `aws --version`을 사용하여 aws cli 버전을 확인하세요. 또한 터미널에서 라이브 로그를 추적하는 데 도움이 되는 이 유틸리티 스크립트를 사용하는 것이 좋습니다.

V1의 경우:

```
aws logs get-log-events \
  --log-group-name /aws/sagemaker/YourLogGroupName \
  --log-stream-name YourLogStream \
  --start-from-head | jq -r '.events[].message'
```

V2의 경우:

```
aws logs tail /aws/sagemaker/YourLogGroupName \
  --log-stream-name YourLogStream \
  --since 10m \
  --follow
```

d) ML 흐름 설정:

MLflow를 통해 지표를 추적할 수 있습니다.

MLflow 앱 생성

Studio UI 사용: Studio UI를 통해 훈련 작업을 생성하는 경우 기본 MLflow 앱이 자동으로 생성되고 고급 옵션에서 기본적으로 선택됩니다.

CLI 사용: CLI를 사용하는 경우 MLflow 앱을 생성하고 이를 훈련 작업 API 요청에 대한 입력으로 전달해야 합니다.

```
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)
```

MLflow 앱에 액세스

CLI 사용: 미리 서명된 URL을 생성하여 MLflow 앱 UI에 액세스합니다.

```
aws sagemaker create-presigned-mlflow-app-url \
  --arn $mlflow_app_arn \
  --region $region \
  --output text
```

ML 흐름이 설정되면 레시피에서 URI를 전달하거나 작업을 시작할 때 재정의의 사용할 수 있습니다. 이를 수행하는 방법에 대한 한 가지 예제는 README에서 확인할 수 있습니다.

SFT 이후 모델을 평가하려면 어떻게 해야 하나요?

사전 조건

- 훈련 작업 manifest.json 파일의 체크포인트 S3 URI(훈련된 모델의 경우)
- 올바른 형식으로 S3에 업로드된 평가 데이터세트
- 평가 결과에 대한 출력 S3 경로

즉시 사용 가능한 벤치마크: 즉시 사용 가능한 벤치마크를 통해 일반 태스크의 성능을 검증합니다. 자세한 내용은 여기에서 확인하세요.

자체 데이터 사용:

또한 아래 형식으로 지정한 다음 아래에 언급된 컨테이너를 사용하여 필요한 경우 보정에 대한 로그 확률과 함께 추론 결과를 가져와 사용자 지정 데이터를 제공할 수 있습니다.

다음 구조를 사용하여 태스크당 jsonl을 생성합니다.

```
{
  "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"
}
```

평가 작업의 추론 단계 중에 생성된 출력의 구조는 다음과 같습니다.

```
{
```

```

"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'}"
}

```

필드 설명:

- prompt: 모델로 전송된 형식 지정된 입력
- 추론: 모델의 생성된 응답
- gold: 입력 데이터세트의 예상되는 정답, 입력의 응답 필드
- 메타데이터: 입력에서 전달되는 선택적 메타데이터

평가 구성 준비

평가 작업을 시작하는 명령. '--override-parameters'를 사용하여 레시피의 모든 항목을 수정합니다.

```

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"
  }'

```

평가 작업 시작

해당되는 이미지를 포함하는 여러 레시피에 대한 명령을 시작하는 작업.

평가 작업 시작 명령

모델	기술	Subcategory	이미지 URI	Command
Nova 2.0	평가	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_2_0/nova_lite/nova_lite_2_0_p5_48_xl_gpu_ft_eval \ --override-parameters '{ "instance_type": "ml.p5.48xlarge", "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-HP-Eval-latest" }'

학습한 교훈 및 팁

- SFT 데이터세트의 품질은 매우 중요합니다. 저품질 데이터를 필터링하기 위해 모든 노력을 기울여야 합니다. 복잡성과 정확성 측면에서 예외적으로 품질이 뛰어난 데이터의 하위 세트가 작은 경우 모델이 더 잘 수렴될 수 있도록 훈련이 끝날 때 배치하는 것이 좋습니다.
- 데이터 혼합을 위해 텍스트 및 멀티모달(MM) 데이터세트를 모두 활용합니다. 텍스트 데이터세트를 사용하는 실험에서는 Nova의 독점 '추론 지침 준수' 범주를 추가할 때 일반 벤치마크 전반에서 성능이 크게 향상되는 것으로 나타났습니다. 사용자 데이터세트로 SFT를 수행한 후 회귀되는 일반 벤치마크에 관심이 있는 경우 데이터 혼합 전략에 이 범주를 포함하는 것이 좋습니다.

- MM 데이터세트의 경우 실험에서는 비디오 범주를 20% 넘게 혼합에 통합하면 일반적인 벤치마크 성능을 유지 관리하는 데 도움이 되는 것으로 나타났습니다.
- 또한 데이터 혼합을 사용하는 SFT는 학습 속도에 매우 민감하므로 연구 결과에 따라 기본 학습 속도 (LoRA의 경우 $1e-5$, FR의 경우 $5e-6$)에서 미세 조정할 것을 제안합니다.
- 마지막으로 Nova 독점 데이터세트를 혼합하면 지연 시간과 성능이 절충되므로 조사 결과에 따라 바람직한 균형 수치로 최대 50%를 혼합할 것을 제안합니다.

강화 학습

Note

구독하면 세부 설명서가 제공됩니다.

Nova Forge는 사용자 환경에서 원격 보상 함수를 사용하는 옵션과 함께 고급 강화 학습 기능을 제공합니다. 고객은 자체 엔드포인트를 통합하여 즉각적인 실제 피드백에 대한 검증을 실행하거나 자체 오케스트레이터를 사용하여 환경에서 에이전트 멀티턴 평가를 조정할 수도 있습니다.

에이전트 멀티턴 평가를 위한 자체 오케스트레이터 가져오기

15분 제한 시간을 초과하는 멀티턴 대화 또는 보상 함수가 필요한 Forge 사용자를 위해 Nova Forge는 자체 오케스트레이션 가져오기(BYOO) 기능을 제공합니다. 이를 통해 환경에서 에이전트 멀티턴 평가를 조정할 수 있습니다(예: 화학 도구를 사용하여 분자 설계 점수를 매기거나 효율적인 태스크 완료에 대한 보상을 제공하고 충돌에 페널티를 적용하는 로봇 시뮬레이션).

주제

- [아키텍처 개요](#)
- [설정 및 실행](#)

아키텍처 개요

BYOO 아키텍처는 고객 관리형 인프라를 통해 롤아웃 및 생성 프로세스를 완벽하게 제어합니다.

훈련 VPC:

- 롤아웃: 고객 인프라에 롤아웃 생성을 위임하여 훈련 조정
- 트레이너: 수신된 롤아웃을 기반으로 모델 가중치 업데이트 수행

고객 VPC(예: EC2 기반 ECS):

- 프록시 Lambda: 롤아웃 요청을 수신하고 고객 인프라에 맞게 조정
- 롤아웃 응답 SQS: 완료된 롤아웃을 훈련 인프라로 반환하기 위한 대기열
- 요청 생성 SQS: 모델 생성 요청에 대한 대기열
- 응답 생성 SQS: 모델 생성 응답에 대한 대기열
- 고객 컨테이너: 사용자 지정 오케스트레이션 로직 구현(제공된 스타터 키트 사용 가능)
- DynamoDB: 오케스트레이션 프로세스 전반에 걸쳐 상태 저장 및 검색

워크플로:

1. 롤아웃은 프록시 Lambda에 롤아웃 생성을 위임함
2. 프록시 Lambda가 롤아웃 API 요청을 푸시하여 요청 생성 SQS로 푸시함
3. 고객 컨테이너에서 요청을 처리하고, 멀티턴 상호 작용을 관리하며, 보상 함수를 직접 호출함
4. 컨테이너는 필요에 따라 DynamoDB에서 상태를 저장 및 검색함
5. 컨테이너가 롤아웃 응답을 롤아웃 응답 SQS로 푸시함
6. 롤아웃은 가중치 업데이트를 위해 완료된 롤아웃을 트레이너에게 전송함

설정 및 실행

자세한 설정 지침, 레시피 구성, 요청 및 응답 형식, 환경 예제는 Nova Forge 구독자에게 제공되는 기밀 설명서를 참조하세요. Nova Forge 문서를 가져오려면 아래 단계를 따릅니다.

```
aws s3 cp s3://nova-forge-c7363-206080352451-us-east-1/v1/ ./ --recursive
```

자산이 다운로드되면 docs 폴더에서 모든 설명서를 찾을 수 있습니다.

책임 있는 AI 도구 키트 및 콘텐츠 조정

책임 있는 AI 도구 키트

Nova Forge는 훈련 프로세스 중에 모델을 Amazon Nova의 책임 있는 AI 지침에 맞추기 위한 훈련 및 평가 데이터를 포함하는 책임 있는 AI 툴킷을 제공하고 추론 중에 모델 응답을 조정하기 위한 런타임 제어를 제공합니다.

훈련 데이터 - 책임 있는 AI 원칙, 안전 고려 사항 및 책임 있는 기술 배포를 강조하는 사례 및 시나리오를 데이터 혼합에 사용하여 지속적인 사전 훈련 중에 모델을 책임감 있게 조정할 수 있습니다.

평가 - 부적절하거나 유해하거나 잘못된 콘텐츠를 감지 및 거부하는 모델의 기능을 테스트하는 평가는 기본 모델 성능과 사용자 지정 모델 성능 간 델타를 결정하는 벤치마크 태스크로 사용할 수 있습니다.

런타임 제어 - 기본적으로 Amazon Nova의 런타임은 추론 중에 중간 모델 응답을 제어합니다. 이러한 런타임 제어를 수정하려면 AWS 계정 관리자에게 문의하여 Amazon Nova의 사용자 지정 가능한 콘텐츠 조정 설정을 요청합니다.

보안은 AWS 및 사용자 간의 공동 책임입니다. 기본 모델을 변경하거나 지속적인 사전 훈련을 사용하여 특정 사용 사례의 성능을 개선하면 새 모델의 안전성, 공정성 및 기타 속성에 영향을 미칠 수 있습니다. 강력한 적응 방법은 기본 모델에 빌드된 안전, 공정성 및 기타 보호 기능의 변경을 최소화하는 동시에 모델이 사용자 지정되지 않은 태스크의 모델 성능에 미치는 영향을 최소화합니다. 테스트 결과가 안전성, 공정성 및 기타 속성과 전반적인 효과에 대한 특정 기대치를 충족하는지 확인하려면 사용 사례를 대표하는 데이터세트에서 애플리케이션을 포괄적으로 테스트해야 합니다. 자세한 내용은 Amazon Web Services 책임 있는 AI 사용 가이드, Amazon Web Services 책임 있는 AI 정책, Amazon Web Services 이용 정책, Amazon Web Services 서비스 약관을 참조하세요.

책임 있는 사용

AI 모델로 안전, 보안 및 신뢰 조치를 구축하는 것은 AWS와 고객 간의 공동 책임입니다. 저희의 목표는 모델을 [AWS 이용 정책](#)에 맞게 조정하고 원치 않는 결과를 완화하는 동시에 만족스러운 고객 경험을 제공하는 것입니다. 책임 있는 AI(RAI)에 대한 접근 방식은 다음 목록에서 다루는 [책임 있는 AI의 핵심 차원](#)을 중심으로 구성됩니다. 이러한 각 차원에 대해 전체 모델 개발 수명 주기 전반에 걸쳐 의사 결정을 관장하는 지침을 개발했습니다. 이 수명 주기는 초기 데이터 수집 및 사전 훈련부터 배포 후 런타임 완화 구현에 이르기까지 모든 단계를 포괄합니다.

- 공정성 - 다양한 이해관계자 그룹에 미치는 영향 고려
- 설명 가능성 - 시스템 출력 이해 및 평가
- 개인 정보 보호 및 보안 - 데이터 및 모델의 적절한 획득, 사용 및 보호
- 안전 - 유해한 출력 및 오용 방지
- 제어 가능성 - AI 시스템 동작을 모니터링하고 조정하는 메커니즘 확보
- 정확성 및 견고성 - 예기치 않거나 적대적인 입력에도 올바른 시스템 출력 달성
- 거버넌스 - 공급자와 배포자를 포함한 AI 공급망에 모범 사례 통합
- 투명성 - 이해관계자가 AI 시스템 참여에 대해 정보에 입각한 선택을 할 수 있도록 지원

지침

모델 개발 지침에는 다음을 미화, 조장 또는 홍보하는 콘텐츠를 조정하는 것을 포함하되 이에 국한되지 않습니다.

- 위험한 활동 참여, 자해 또는 위험 물질 사용
- 규제 약물, 담배 또는 알코올의 사용, 오용 또는 거래
- 신체적 폭력 또는 유혈 장면
- 아동 학대 또는 아동 성적 학대 관련 자료
- 동물 학대 또는 동물 밀매
- 개인이나 집단이 고의적인 사기, 대중의 신뢰를 받는 기관의 명성을 훼손하는 행위, 인간의 건강이나 생계를 위협하는 행위에 책임이 있다고 주장하는 잘못된 정보
- 맬웨어, 악성 콘텐츠 또는 사이버 범죄를 조장하는 모든 콘텐츠
- 개인 또는 집단에 대한 무례, 차별 또는 고정관념
- 모욕, 욕설, 외설적인 몸짓, 노골적인 성적 언어, 음란물, 혐오 상징 또는 혐오 집단

- 과학적, 교육적 또는 참고용 컨텍스트를 벗어난 완전한 나체
- 인구통계학적 특성에 근거한 집단에 대한 편견

권장 사항

사용 적합성: AI 모델 출력은 확률적이기 때문에 Amazon Nova는 부정확하거나 부적절한 콘텐츠를 생성할 수 있습니다. 고객은 특히 최종 사용자에게 직접 노출되는 경우 사용 사례에 대한 출력의 정확성과 적합성을 평가해야 합니다. 또한 Amazon Nova가 중대한 의사 결정을 내리는 고객 워크플로에 사용되는 경우 고객은 사용 사례의 잠재적 위험을 평가하고 적절한 인적 감독, 테스트 및 기타 사용 사례별 안전 조치를 구현하여 이러한 위험을 완화해야 합니다.

프롬프트 최적화: Amazon Nova의 조정을 받는 경우 위의 지침과 관련하여 사용된 프롬프트를 검토해 보세요. 프롬프트를 최적화하여 원치 않는 결과가 생성될 가능성을 줄이는 것이 Amazon Nova 모델을 사용하여 예상 출력을 생성하는 데 권장되는 전략입니다. 모델 성능에 영향을 줄 수 있는 픽셀 콘텐츠를 포함하여 사용자가 입력을 제어하는 부분에 주의하세요. 자세한 내용은 이 사용자 가이드의 프롬프트 지침을 참조하세요. 자세한 내용은 이 사용자 가이드의 프롬프트 지침 섹션을 참조하세요.

개인 정보 보호: Amazon Nova는 Amazon Bedrock에서 사용할 수 있습니다. Amazon Bedrock은 관리형 서비스로, 고객 프롬프트 또는 고객 프롬프트 완성을 저장하거나 검토하지 않으며, 프롬프트와 완성은 고객 간 또는 Amazon Bedrock 파트너와 공유되지 않습니다. AWS는 Amazon Bedrock 서비스를 통해 생성된 입력 또는 출력을 사용하여 Amazon Nova를 포함한 Amazon Bedrock 모델을 훈련하지 않습니다. 자세한 내용은 AWS 서비스 약관의 [50.3](#) 섹션과 AWS [데이터 프라이버시 FAQ](#)를 참조하세요. 서비스별 개인 정보 보호 정보는 [Amazon Bedrock FAQs](#) 설명서의 개인 정보 보호 및 보안 섹션을 참조하세요. Amazon Nova는 개인 정보를 요청하는 것으로 해석될 수 있는 프롬프트를 작성하지 않도록 조치를 취하고 있습니다. Amazon Nova 완성에 개인 정보가 포함되었다고 의심되는 경우 [여기](#)로 문의해 주세요.

보안: Amazon Nova를 포함한 모든 Amazon Bedrock 모델에는 고객이 GDPR 및 HIPAA를 포함한 일반적인 데이터 보안 및 규정 준수 표준을 지원하는 생성형 AI 애플리케이션을 구축할 수 있도록 지원하는 엔터프라이즈 보안 기능이 포함되어 있습니다. 고객은 AWS PrivateLink를 사용하여 고객 트래픽을 인터넷에 노출하지 않고 사용자 지정된 Amazon Nova와 온프레미스 네트워크 간에 프라이빗 연결을 설정할 수 있습니다. 고객 데이터는 전송 중 및 저장 중 항상 암호화되며, 고객은 AWS Key Management Service를 사용하는 등 자체 키로 데이터를 암호화할 수 있습니다. 고객은 AWS Identity and Access Management를 통해 사용자 지정된 Amazon Nova를 포함한 Amazon Bedrock 리소스에 대한 액세스를 안전하게 제어할 수 있습니다. 또한 Amazon Bedrock은 고객 거버넌스 및 감사 요구 사항을 지원하는 포괄적인 모니터링 및 로깅 기능을 제공합니다. 예를 들어 Amazon CloudWatch는 감사 목적에 필요한 사용 지표를 추적하는 데 도움이 되며, AWS CloudTrail은 Amazon Nova가 다른 AWS

시스템과 통합되어 있으므로 API 활동을 모니터링하고 문제를 해결하는 데 도움이 됩니다. 고객은 메타데이터, 프롬프트 및 완성을 자체 암호화된 Amazon Simple Storage Service(Amazon S3) 버킷에 저장하도록 선택할 수도 있습니다.

지적 재산: AWS는 일반 공개된 Amazon Nova 모델의 출력에 대해 무제한 지적 재산(IP) 면책 보상을 제공합니다([서비스 약관](#) 50.10항 참조). 즉, 고객은 이러한 Amazon Nova 모델에서 생성된 출력에 의한 IP 침해 또는 유용(저작권 클레임 포함)을 주장하는 타사 클레임으로부터 보호됩니다. 또한 서비스 사용에 대한 당사의 표준 IP 면책 조항은 서비스(Amazon Nova 모델 포함) 및 이를 훈련하는 데 사용된 데이터에 의한 IP 침해(저작권 클레임 포함)를 주장하는 제3자 클레임으로부터 고객을 보호합니다.

Amazon Nova 할당량

AWS 계정에는 Amazon Bedrock에 대한 기본 할당량(이전에는 한도라고 함)이 있습니다. Amazon Bedrock의 서비스 할당량을 보려면 다음 중 하나를 수행합니다.

- [Viewing service quotas](#)의 단계에 따라 서비스로 Amazon Bedrock을 선택합니다.
- AWS 일반 참조의 [Amazon Bedrock endpoints and quotas](#)를 참조하세요.

Note

할당량이 Service Quotas를 통해 조정 불가능한 항목으로 표시되는 경우 할당량 증가를 고려하도록 [제안 증가 양식](#)을 통해 요청을 제출할 수 있습니다.

서비스 성능을 유지하고 Amazon Bedrock을 적절하게 사용할 수 있도록, 계정에 할당된 기본 할당량은 지역적 요인, 결제 기록, 사기성 사용 및/또는 할당량 증가 요청 승인에 따라 업데이트될 수 있습니다.

Amazon Nova 할당량 증가 요청

다음 단계에 따라 계정에 할당량 증가를 요청할 수 있습니다.

- AWS 일반 참조에서 [Amazon Bedrock endpoints and quotas](#)의 Adjustable 열에서 할당량이 Yes로 표시된 경우, [Service Quotas 사용 설명서](#)의 Service Quotas 사용 설명서에서 [Requesting a Quota Increase](#)의 단계에 따라 할당량을 조정할 수 있습니다.
- AWS 일반 참조에서 [Amazon Bedrock endpoints and quotas](#)의 온디맨드 모델 간접 호출 할당량은 Service Quotas를 통해 조정할 수 없습니다. 할당량을 늘리는 것을 고려하고 있다면 AWS 계정 관리자에게 문의하세요.

Note

수요가 압도적인 관계로, 기존에 할당된 할당량을 소비하는 트래픽을 생성하는 고객에게 우선 순위가 부여됩니다. 이 조건을 충족하지 않으면 요청이 거부될 수 있습니다.

- AWS 일반 참조의 [Amazon Bedrock endpoints and quotas](#)에서 Adjustable 열에 할당량이 No로 표시된 경우에도 [한도 증가 양식](#)을 통해 요청을 제출하면 할당량 증가가 고려될 수 있습니다.

Amazon Nova 모니터링

Amazon Nova 및 다른 AWS 솔루션의 신뢰성, 가용성 및 성능을 유지하려면 모니터링이 중요합니다. AWS는 Amazon Nova를 모니터링하고, 이상이 있을 때 이를 보고하며, 필요한 경우 자동 조치를 취할 수 있도록 다음과 같은 모니터링 도구를 제공합니다.

Amazon Nova는 Amazon Bedrock을 통해 사용할 수 있으므로 [Monitor the health and performance of Amazon Bedrock](#)의 모든 모니터링 가이드를 따르세요.

Amazon Nova의 보안

AWS에서 클라우드 보안은 가장 중요합니다. AWS 고객은 보안에 가장 보안에 민감한 조직의 요구 사항에 부합하도록 빌드된 데이터 센터 및 네트워크 아키텍처의 혜택을 누릴 수 있습니다.

보안은 AWS와 사용자의 공동 책임입니다. [공동 책임 모델](#)은 이 사항을 클라우드의 보안 및 클라우드 내 보안으로 설명합니다.

- 클라우드의 보안 - AWS는 AWS 클라우드에서 AWS 서비스를 실행하는 인프라를 보호합니다. AWS는 또한 안전하게 사용할 수 있는 서비스를 제공합니다. 타사 감사자는 [AWS 규정 준수 프로그램](#)의 일환으로 보안 효과를 정기적으로 테스트하고 검증합니다. Amazon Nova에 적용되는 규정 준수 프로그램에 대한 자세한 내용은 [규정 준수 프로그램별 AWS 서비스 범위](#)를 참조하세요.
- 클라우드 내 보안 - 귀하의 책임은 귀하가 사용하는 AWS 서비스에 따라 결정됩니다. 또한 귀하는 귀사의 데이터 민감도, 귀사의 요구 사항, 관련 법률 및 규정을 비롯한 기타 요소에 대해서도 책임이 있습니다.

Amazon Nova는 Amazon Bedrock을 통해 제공되므로 [Security in Amazon Bedrock](#)의 모든 보안 가이드를 따르세요.

AWS CloudFormation을 사용하여 Amazon Nova 리소스 생성

CloudFormation에서 Amazon Bedrock을 통해 Amazon Nova 모델을 배포하는 경우 [Create Amazon Bedrock resources with CloudFormation](#)의 모든 CloudFormation 지침을 따릅니다.

YOUR-RESOURCE-PLURAL에 대한 JSON 및 YAML 템플릿 예제를 포함한 자세한 내용은 AWS CloudFormation 사용 설명서의 [YOUR-SERVICE-RESOURCE-TOPNODE-IN-CLOUDFORMATION\(local-phrases.ent 파일에서 이 링크 수정\)](#)을 참조하세요.

CloudFormation에 대해 자세히 알아보기

CloudFormation에 대한 자세한 내용은 다음 리소스를 참조하세요.

- [AWS CloudFormation](#)
- [AWS CloudFormation 사용자 안내서](#)
- [CloudFormation API 참조](#)
- [AWS CloudFormation 명령줄 인터페이스 사용자 안내서](#)

Amazon Nova 개발자 안내서에 대한 문서 기록

다음 표에서는 Amazon Nova 2.0에 대한 설명서 릴리스를 설명합니다.

변경 사항	설명	날짜
Amazon Nova 2.0의 최초 릴리스	새 모델이 포함된 Amazon Nova 2.0 개발자 안내서의 최초 릴리스: Nova 2 Lite, Amazon Nova Sonic. 이 안내서에서는 모든 모델 티어에서 향상된 멀티모달 기능, 추론 기능 및 향상된 성능을 소개합니다.	2025년 12월 2일