



Panduan Pengembang untuk Amazon Nova 2

Amazon Nova



Amazon Nova: Panduan Pengembang untuk Amazon Nova 2

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

Merek dagang dan tampilan dagang Amazon tidak boleh digunakan sehubungan dengan produk atau layanan apa pun yang bukan milik Amazon, dengan cara apa pun yang dapat menyebabkan kebingungan di antara pelanggan, atau dengan cara apa pun yang merendahkan atau mendiskreditkan Amazon. Semua merek dagang lain yang tidak dimiliki oleh Amazon merupakan hak milik masing-masing pemiliknya, yang mungkin atau mungkin tidak terafiliasi, terkait dengan, atau disponsori oleh Amazon.

Table of Contents

Apa itu Amazon Nova 2?	1
Konsep utama	1
Model Amazon Nova	2
Apa yang bisa Anda bangun?	2
Manfaat	3
Bagaimana Amazon Nova bekerja	3
Harga	4
Langkah selanjutnya	4
Apa yang baru di Amazon Nova 2	5
Model baru	5
Fitur dan kemampuan baru	5
Penyematan Multimodal Nova	5
Pemikiran dan penalaran yang diperluas	5
Alat bawaan	6
Bangunan agen AI	6
Peningkatan pemahaman dokumen	6
Pemahaman video yang ditingkatkan	6
Kustomisasi model	6
Amazon Nova Forge	7
Langkah selanjutnya	7
Memulai	8
Memulai di konsol	8
Jelajahi taman bermain teks	9
Memulai dengan API	9
Dapatkan kredensial untuk memberikan akses terprogram	11
Lampirkan izin Amazon Bedrock ke pengguna atau peran	12
Hasilkan respons untuk prompt teks menggunakan model Amazon Nova	13
Inferensi inti	14
Penting: Konfigurasi Batas Waktu	15
Topik Inferensi Inti	15
Menggunakan Converse API	16
Struktur permintaan	16
Menggunakan prompt sistem	17
Parameter inferensi	18

Menggunakan penalaran	19
Menggunakan API Invoke	21
Struktur permintaan	22
Permintaan parameter	23
Respons streaming	23
Streaming dengan ConverseStream	23
Streaming dengan InvokeModelWithResponseStream	24
Jenis acara streaming	24
Menggunakan penyematan Amazon Nova	25
Fitur utama	25
Menghasilkan embeddings	26
Inferensi sesuai permintaan	29
Manfaat	30
Menggunakan inferensi sesuai permintaan	30
Harga	30
Kuota dan batas	31
Menggunakan kemampuan Nova	32
Penalaran	32
Pemahaman multimodal	33
Jenis konten yang didukung berdasarkan modalitas	33
Pemahaman gambar	34
Pemahaman video	37
Pemahaman dokumen	39
Pidato ke Ucapan	42
Fitur utama	42
Memulai	43
Nyatakan impor dan konfigurasi	43
Tentukan SimpleNovaSonic kelas	44
Inisialisasi klien	45
Menangani acara	45
Mulai sesi	45
Menangani input audio	48
Akhir sesi	50
Menangani tanggapan	50
Pemutaran audio	52
Tangkap audio	53

Jalankan fungsi utama	54
Contoh kode	55
Memulai contoh	55
Kasus penggunaan lanjutan	56
Bengkel langsung	57
Permintaan percakapan suara	57
Pedoman Penting	57
Prompt Sistem Dasar yang Direkomendasikan untuk Suara	58
Konfigurasi Speech Prompt	58
Konfigurasi Prompt Sistem	59
Perjanjian Gender untuk Bahasa Gender	60
Rantai pemikiran untuk Pidato: Penalaran Konstitusional	61
Terlalu sering menggunakan frasa yang disarankan	62
Konsep inti	64
Siklus hidup acara	64
Urutan aliran acara	66
Menangani peristiwa masukan dengan API dua arah	66
Menangani peristiwa keluaran dengan API dua arah	75
Tongkang	82
Kontrol pengambilan giliran	83
Masukan lintas modal	85
Dukungan bahasa dan kemampuan multibahasa	88
Mengelola riwayat obrolan	89
Konfigurasi alat	95
Panggilan alat asinkron	103
Integrasi	106
Agen Helai	106
Integrasi kerangka kerja	109
Sistem canggih dengan Nova	120
Ikhtisar	120
Pemikiran yang Diperpanjang	120
Bagaimana Extended Thinking Bekerja	120
Opsi konfigurasi	123
Model yang didukung	124
Pemikiran yang diperluas dengan penggunaan alat	124
Memahami Token Penalaran dan Harga	124

Pertanyaan yang Sering Diajukan	125
Penggunaan alat	126
Memahami alur kerja penggunaan alat	126
Buat alat	127
Panggil alat	130
Alat sistem bawaan	133
Membangun agen AI	136
Buat agen	136
Meminta agen	138
Pembumian Web	141
Bagaimana Web Grounding bekerja	141
Cara menggunakan Web Grounding	141
Ketersediaan wilayah	142
Struktur respons	142
Keamanan grounding	143
Penanganan kesalahan	144
Izin diperlukan untuk alat bawaan	144
Rekayasa yang cepat	146
Apa itu rekayasa cepat	146
Memulai dengan rekayasa yang cepat	146
Praktik terbaik	147
Memahami peran	147
Buat petunjuk yang tepat	148
Bawa fokus ke bagian prompt	167
Menggunakan peran sistem	168
Berikan contoh (beberapa bidikan yang diminta)	176
Sistem panggilan alat	186
Teknik meminta tingkat lanjut	188
Meminta input multimodal	209
Pedoman multimodal umum	210
Pemahaman Dokumen dan Gambar	211
Pemahaman video	37
Moderasi konten	222
Prinsip-prinsip kunci	223
Konfigurasi yang disarankan	223
MLCommons taksonomi universal	223

Contoh yang mendorong	225
Kode dan Pemecahan Masalah	231
Pustaka kode	231
Contoh API Converse	231
InvokeModel Contoh API	251
Pemecahan masalah	256
Otentikasi dan pengaturan	256
Akses model ditolak	257
Masalah ketersediaan regional	257
Konfigurasi waktu habis	257
Masalah respons API	258
Kesalahan mode penalaran	259
Masalah penggunaan alat	260
Referensi API dan SDK	264
Skema permintaan dan respons	264
Struktur permintaan lengkap	264
Struktur respons lengkap	269
Referensi SDK	272
Kustomisasi model Amazon Nova	273
Pendekatan kustomisasi	273
Platform kustomisasi	274
Prasyarat umum	275
Resep Amazon Nova	276
Mendapatkan resep dasar	277
Mendapatkan resep Forge	277
Model dan algoritma yang tersedia	278
Amazon Nova 2.0 Lite	278
Pada pekerjaan SageMaker pelatihan	286
Praktik Terbaik untuk kustomisasi Amazon Nova	287
Nova Forge SDK	292
Pelatihan	298
Memantau Kemajuan di Seluruh Iterasi	334
Evaluasi	339
Pelatihan berulang	405
Pada SageMaker HyperPod	406
Persyaratan komputasi untuk model Amazon Nova 2	407

Praktik Terbaik untuk kustomisasi Amazon Nova	287
Nova Forge SDK	413
Pengaturan klaster HP	413
Panduan Perintah Penting	413
Akses dan pengaturan Nova Forge	424
Pelatihan	426
Evaluasi	466
MLflow pemantauan	516
Pelatihan Iteratif	519
Ikhtisar	519
Cara kerjanya	520
Kapan harus menggunakan pelatihan berulang	521
Contoh alur kerja: SFT → RFT	522
Memantau kemajuan di seluruh iterasi	524
Praktik terbaik	526
Pertimbangan Biaya	528
Batasan	528
Pemecahan masalah	530
SageMaker Inferensi	531
Fitur	532
Model dan instance yang didukung	533
AWS Wilayah yang Didukung	535
Gambar Kontainer yang Didukung	535
Praktik Terbaik	536
Support	536
Memulai	536
Referensi API	557
Mengevaluasi model	567
Deteksi penyalahgunaan untuk Amazon Nova Forge	573
Inferensi Batuan Dasar Amazon	575
Menerapkan model khusus untuk inferensi sesuai permintaan	575
Inferensi sesuai permintaan	581
Batasan	583
Nova Forge	584
Prasyarat	584
Berlangganan Nova Forge	584

Prasyarat lainnya	585
Akses dan pengaturan Nova Forge	585
Mendapatkan dokumen Nova Forge	585
Langkah 1: Berlangganan Nova Forge	586
Langkah 2. Menyiapkan HyperPod infrastruktur	591
Pengaturan moderasi konten	592
Lanjutan Pra-Pelatihan dan Pertengahan Pelatihan	592
Apa itu pos pemeriksaan menengah dan mengapa mereka dibutuhkan?	592
Pos pemeriksaan apa yang tersedia?	593
Pos pemeriksaan mana yang akan digunakan?	594
Bagaimana cara menggunakan pencampuran data untuk Nova 2.0?	595
Membedah Kategori Pencampuran Data	597
Fine-Tuning yang Diawasi	601
Pengantar	601
Kapan menggunakan SFT?	602
Kapan menggunakan parameter efisien dan kapan peringkat penuh SFT?	602
Pencampuran Data untuk SFT	603
Contoh Konfigurasi YAMB	604
Pos Pemeriksaan Model	606
Pendekatan Pelatihan	606
Prasyarat sebelum Anda mulai	607
Pendekatan Sistematis untuk Mencapai SFT yang Sukses	608
Pengurutan Eksperimen dan Pencampuran Data	609
Siapkan Dataset untuk SFT	609
Metode Evaluasi	610
Praktik Terbaik	287
Siapkan Training Job Config	612
Mengatur Blok Pencampuran Data	613
Cara Meluncurkan Pekerjaan	619
Cara Memantau Job	628
Bagaimana cara mengevaluasi model Anda setelah SFT?	630
Pelajaran dan Tips	633
Pembelajaran Penguatan	633
Bawa orkestrator Anda sendiri untuk evaluasi multi-putaran agen	634
Toolkit AI yang Bertanggung Jawab	635
Toolkit AI yang bertanggung jawab	635

Penggunaan yang bertanggung jawab	637
Pedoman	637
Rekomendasi	638
Kuota	640
Minta kenaikan kuota Amazon Nova	640
Memantau	642
Keamanan	643
Membuat sumber daya dengan CloudFormation	644
Pelajari lebih lanjut tentang CloudFormation	644
Riwayat dokumen	645
.....	dcxlv

Apa itu Amazon Nova 2?

Amazon Nova menyediakan model dasar multimodal yang memproses teks, gambar, video, dokumen, dan ucapan. Dengan dukungan hingga 1 juta token konteks dan kemampuan penalaran tingkat lanjut, model Amazon Nova 2 memungkinkan Anda membangun aplikasi AI canggih yang memahami input kompleks dan menghasilkan respons yang akurat.

Anda dapat membangun chatbots interaktif, menganalisis dokumen dan video, membuat agen AI dengan penalaran yang diperluas dan mengembangkan aplikasi berkemampuan suara.

Konsep utama

Sebelum Anda mempelajari tentang model Amazon Nova, biasakan diri Anda dengan konsep inti berikut:

Model pondasi

Sistem AI pra-terlatih tersedia dalam berbagai ukuran dan kemampuan yang Anda akses melalui API.

Inferensi

Proses pengiriman permintaan ke model dan menerima respons yang dihasilkan.

Penalaran

Kemampuan berpikir yang diperluas yang memungkinkan model untuk memecah masalah yang kompleks dan menunjukkan step-by-step analisisnya sebelum memberikan jawaban.

Multimodal

Kemampuan untuk memproses dan memahami beberapa jenis input bersama-sama: teks, gambar, video dan dokumen dalam satu permintaan.

RAG (Generasi Augmented Retrieval-Augmented)

Teknik yang menggabungkan respons model dengan sumber data Anda sendiri untuk memberikan jawaban kontekstual yang lebih akurat.

Model Amazon Nova

Amazon Nova 2 menyertakan model-model berikut, masing-masing dioptimalkan untuk kasus penggunaan yang berbeda:

Model	Modalitas masukan	Modalitas keluaran	Kasus penggunaan
Nova 2 Lite	Teks, gambar, video, dokumen	Teks	Aplikasi volume tinggi yang memprioritaskan kecepatan dan efisiensi biaya
Nova 2 Sonic	Pidato, teks	Pidato, teks	Aplikasi berkemampuan suara dengan waktu respons cepat
Embeddings Multimodal Nova	Teks, gambar, dokumen, video, audio	Embeddings	Pencarian semantik, sistem rekomendasi, dan pencocokan kesamaan

Semua model mendukung hingga 1 juta token konteks dan dapat menghasilkan hingga 65.536 token dalam satu respons. Model dengan kemampuan penalaran dapat melakukan pemikiran yang diperluas untuk memecahkan masalah kompleks selangkah demi selangkah.

Apa yang bisa Anda bangun?

Berikut ini adalah contoh dari apa yang dapat Anda bangun dengan Amazon Nova:

- Asisten dokumen cerdas - Memproses dokumen besar dengan hingga 1 juta token konteks untuk menjawab pertanyaan dan mengekstrak wawasan (dengan RAG)
- Aplikasi penalaran kompleks - Memecahkan masalah multi-langkah dengan pemikiran yang diperluas yang menunjukkan step-by-step analisis model (atau dengan penalaran)
- Pipa analisis video - Ekstrak wawasan, buat ringkasan, dan identifikasi momen penting dalam konten video dalam skala besar (Nova 2 Lite)
- Agen AI berkemampuan suara - Bangun agen percakapan yang memahami input ucapan dan merespons dengan bahasa alami (Nova 2 Sonic)

Manfaat

Amazon Nova memberikan manfaat berikut:

Pemahaman multimodal

Proses teks, gambar, video, dokumen, dan pidato dalam satu permintaan. Model Amazon Nova memahami hubungan di berbagai jenis input.

Konteks yang diperluas

Support hingga 1 juta token memungkinkan Anda memproses seluruh basis kode, dokumen panjang, atau percakapan yang diperpanjang tanpa kehilangan konteks.

Penalaran tingkat lanjut

Model dengan kemampuan penalaran memecah masalah kompleks dan menunjukkan step-by-step analisis, meningkatkan akurasi untuk tugas multi-langkah.

Penyebaran yang fleksibel

Akses model melalui Amazon Bedrock tanpa infrastruktur untuk dikelola, atau sesuaikan model melalui fine-tuning dan pembelajaran penguatan.

Alat bawaan

Gunakan web grounding untuk mengakses informasi real-time dan kode interpreter untuk mengeksekusi kode Python tanpa integrasi eksternal.

Bagaimana Amazon Nova bekerja

Model Amazon Nova adalah model dasar yang Anda akses melalui Amazon Bedrock. Alur kerja dasarnya adalah:

1. Aplikasi Anda mengirimkan permintaan ke Amazon Bedrock dengan parameter input dan konfigurasi Anda.
2. Model Amazon Nova memproses input Anda, menerapkan penalaran jika dikonfigurasi.
3. Model menghasilkan respons dan mengembalikannya ke aplikasi Anda.

Anda dapat meningkatkan respons dengan menggunakan RAG untuk menggabungkan data Anda, mengaktifkan alat bawaan, atau menyesuaikan model melalui fine-tuning.

Harga

Harga Amazon Nova didasarkan pada token input dan output yang diproses. Model yang berbeda memiliki tingkatan harga yang berbeda:

- Nova 2 Lite - Dioptimalkan untuk pemrosesan volume tinggi yang hemat biaya
- Nova 2 Sonic - Harga seimbang untuk aplikasi berkemampuan suara

Untuk informasi harga saat ini, lihat [Harga Amazon Bedrock](#).

Langkah selanjutnya

- Untuk mempelajari tentang fitur baru di Amazon Nova 2, lihat [Apa yang baru di Amazon Nova 2](#).
- Untuk mulai menggunakan Amazon Nova, lihat [Memulai dengan Amazon Nova 2](#).
- Untuk mempelajari tentang kemampuan inferensi inti, lihat [Inferensi inti](#).
- Untuk menyesuaikan model untuk kasus penggunaan Anda, lihat [Menyesuaikan model Amazon Nova di AI SageMaker](#).

Apa yang baru di Amazon Nova 2

Amazon Nova 2 memperkenalkan peningkatan signifikan di seluruh kemampuan pemahaman, kreatif, dan ucapan. Bagian berikut menjelaskan fitur dan peningkatan baru utama.

Model baru

Nova 2 Lite

Model yang disempurnakan yang menawarkan penalaran lanjutan dengan dukungan pemikiran yang diperluas, kontrol intensitas tiga tingkat, dan pemahaman multimodal yang dioptimalkan untuk alur kerja agen skala produksi.

Nova 2 Sonic

Model ucapan percakapan yang ditingkatkan dengan pemahaman ucapan yang ditingkatkan, pemrosesan bahasa alami, dan kemampuan pembuatan suara di tujuh bahasa.

Penyematan Multimodal Nova

Model penyematan multimodal yang memproses input teks, gambar, dokumen, video dan audio dan menghasilkan penyematan.

Fitur dan kemampuan baru

Penyematan Multimodal Nova

Nova Multimodal Embeddings mendukung teks, dokumen, gambar, video dan audio melalui satu model, memungkinkan aplikasi pengambilan lintas modal. Nova Multimodal Embeddings memetakan masing-masing jenis konten ini ke dalam ruang semantik terpadu, memungkinkan Anda untuk melakukan operasi vektor unimodal, lintas-modal dan multimodal, memberi daya pada aplikasi seperti agentic retrieval-augmented generation (RAG) dan pencarian semantik multimodal.

Pemikiran dan penalaran yang diperluas

Nova 2 Lite mendukung pemikiran yang diperluas, yang memungkinkan model menghabiskan lebih banyak waktu untuk bernalar melalui masalah yang kompleks sebelum menghasilkan respons.

Kemampuan ini meningkatkan akurasi untuk tugas penalaran multi-langkah, termasuk alur kerja agen dengan beberapa alat, matematika tingkat lanjut, perencanaan kompleks, dan pembuatan kode.

Untuk mempelajari lebih lanjut, navigasikan ke [Pemikiran yang diperluas di Amazon Nova 2](#).

Alat bawaan

Amazon Nova 2 menyertakan alat bawaan yang memperluas kemampuan model tanpa memerlukan integrasi eksternal:

- Web grounding — Mengakses informasi real-time dari web untuk memberikan up-to-date tanggapan dan mengurangi halusinasi.
- Kode interpreter - Mengeksekusi kode Python untuk melakukan perhitungan.

Bangunan agen AI

Model Amazon Nova 2 dioptimalkan untuk membangun agen AI. Model menyediakan penggunaan alat yang lebih baik, penalaran yang lebih baik untuk tugas multi-langkah dan kemampuan yang ditingkatkan untuk mempertahankan konteks di seluruh alur kerja agen yang kompleks.

Peningkatan pemahaman dokumen

Nova 2 Lite menyediakan kemampuan pemrosesan dokumen yang ditingkatkan dengan pemahaman yang lebih baik tentang tata letak dokumen yang kompleks, tabel, bagan, dan dokumen multi-halaman. Model mengekstrak informasi lebih akurat dari PDFs, spreadsheet dan format dokumen lainnya.

Pemahaman video yang ditingkatkan

Nova 2 Lite menawarkan kemampuan analisis video yang ditingkatkan, termasuk persepsi visual yang lebih baik, pemahaman temporal, pengenalan tindakan, dan kemampuan untuk memproses urutan video yang lebih lama dengan akurasi yang lebih tinggi.

Kustomisasi model

Nova 2 Lite mendukung fine-tuning (SFT) dan reinforcement fine-tuning (RFT) yang diawasi di Amazon Bedrock SageMaker dan AI, memungkinkan Anda menyesuaikan Amazon Nova 2 dengan kebutuhan bisnis spesifik Anda.

Amazon Nova Forge

Amazon Nova Forge adalah first-of-its-kind layanan yang menawarkan organisasi cara termudah dan paling hemat biaya untuk membangun model perbatasan mereka sendiri menggunakan Amazon Nova.

Langkah selanjutnya

- Untuk mempelajari tentang model dan kemampuan Amazon Nova, lihat [Apa itu Amazon Nova 2?](#).
- Untuk mulai menggunakan Amazon Nova 2.0, lihat [Memulai dengan Amazon Nova 2](#).
- Untuk menjelajahi fitur inferensi inti, lihat [Inferensi inti](#).

Memulai dengan Amazon Nova 2

Anda dapat memanggil model Amazon Nova 2 melalui metode berikut:

- Operasi Amazon Bedrock [InvokeModel](#) atau [Converse API](#)
- [Taman bermain Obrolan dan Teks](#) Amazon Bedrock untuk Nova 2 Lite, Nova 2 Sonic

Important

Jika Anda baru AWS atau ke Amazon Bedrock, Anda harus terlebih dahulu mengatur Amazon Bedrock dengan mengikuti langkah-langkah di [Memulai dengan Amazon Bedrock](#). Atau, Anda dapat mencoba model Amazon Nova tanpa memasuki Amazon Bedrock di nova.amazon.com atau mulai membangun secara gratis di nova.amazon.com/dev.

Pilih topik untuk memulai menggunakan Amazon Nova dengan metode itu.

Memulai dengan Amazon Nova di konsol Amazon Bedrock

Bagian ini menjelaskan cara menggunakan taman bermain di AWS konsol untuk mengirimkan prompt teks ke model Amazon Nova 2 dan menghasilkan respons teks atau gambar. Sebelum Anda menjalankan contoh berikut, Anda harus memeriksa apakah Anda telah memenuhi prasyarat berikut:

Prasyarat

- Anda memiliki AWS akun dan memiliki izin untuk mengakses peran di akun itu dengan izin yang diperlukan untuk Amazon Bedrock. Jika tidak, ikuti langkah-langkah di [Memulai dengan Amazon Bedrock](#).
- Jika Anda mengakses model dari wilayah AS, Anda harus menggunakan titik akhir CRIS AS yang melibatkan penambahan us awalan ke ID model (seperti). `us.amazon.nova-2-lite-v1:0`
- Jika Anda mengakses model dari luar AS, Anda dapat menggunakan titik akhir CRIS global (seperti `global.amazon.nova-2-lite-v1:0`) atau awalan wilayah di ID model (seperti `us//.eu.jp`)

Jelajahi taman bermain teks

Contoh berikut menunjukkan bagaimana menggunakan taman bermain teks:

1. Buka konsol Amazon Bedrock di <https://console.aws.amazon.com/bedrock/>.
2. Dari panel navigasi kiri, pilih Obrolan/Teks di bawah Taman Bermain.
3. Pilih model dan pilih penyedia dan model. Untuk contoh ini, pilih Amazon lalu pilih model Amazon Nova 2 (seperti Nova 2 Lite, atau Nova 2 Sonic). Lalu, pilih Terapkan.
4. Pilih prompt default dari bawah panel teks, atau masukkan prompt ke panel teks, seperti **Describe the purpose of a "hello world" program in one line.**
5. Untuk menjelajahi kemampuan pemahaman gambar Amazon Nova, Anda dapat mengunggah gambar dalam format JPEG, PNG, GIF, atau WEBP yang kurang dari atau sama dengan 25 MB dari komputer Anda. Setelah gambar diunggah, Anda dapat bertanya kepada Amazon Nova tentang gambar tersebut.
6. Untuk menjelajahi kemampuan pemahaman dokumen Amazon Nova, Anda dapat mengunggah dokumen dalam format CSV, DOC, DOCX, HTML, MD, PDF, TXT, XLS, atau XLSX yang kurang dari atau sama dengan 4,5 MB. Setelah dokumen diunggah, Anda dapat bertanya kepada Amazon Nova tentang dokumen tersebut.
7. Untuk menjelajahi kemampuan pemahaman video Amazon Nova, Anda dapat mengunggah satu video dalam MKV, MOV, atau MP4 format yang kurang dari atau sama dengan 25 MB dari komputer Anda. Anda dapat menggunakan Amazon S3 untuk video hingga 1 GB. Setelah video diunggah, Anda dapat bertanya kepada Amazon Nova tentang video tersebut.
8. Pilih Jalankan untuk menjalankan inferensi pada model. Teks yang dihasilkan muncul di bawah prompt Anda di panel teks.

Memulai dengan API

Sebelum Anda memulai APIs, ikuti prosedur ini jika Anda baru AWS atau perlu menginstal AWS CLI atau SDK. AWS Jika tidak satu pun dari ini berlaku untuk Anda, pindah ke [Dapatkan kredensial untuk memberikan akses terprogram](#).

Saya baru AWS

Jika Anda tidak memiliki AWS akun, selesaikan langkah-langkah berikut untuk membuatnya. Atau, Anda dapat mulai membangun secara gratis dengan Amazon Nova di nova.amazon.com/dev.

Untuk mendaftar AWS akun

1. Buka <https://portal.aws.amazon.com/billing/pendaftaran>.
2. Ikuti petunjuk online.

Bagian dari prosedur pendaftaran melibatkan menerima panggilan telepon atau pesan teks dan memasukkan kode verifikasi pada keypad telepon.

Saat Anda mendaftar untuk AWS akun, pengguna root AWS akun dibuat. Pengguna root memiliki akses ke semua AWS layanan dan sumber daya di akun. Sebagai praktik terbaik keamanan, tetapkan akses administratif ke pengguna dan gunakan hanya pengguna root untuk melakukan [tugas yang memerlukan akses pengguna root](#).

AWS mengirim Anda email konfirmasi setelah proses pendaftaran selesai. Kapan saja, Anda dapat melihat aktivitas akun Anda saat ini dan mengelola akun Anda dengan masuk <https://aws.amazon.com/ke/> dan memilih Akun Saya.

Amankan pengguna root AWS akun Anda

1. Masuk ke [Konsol Manajemen AWS](#) sebagai pemilik akun dengan memilih pengguna Root dan memasukkan alamat email AWS akun Anda. Di laman berikutnya, masukkan kata sandi.

Untuk bantuan masuk menggunakan pengguna root, lihat [Masuk sebagai pengguna root](#) di Panduan Pengguna AWS Masuk.

2. Mengaktifkan autentikasi multi-faktor (MFA) untuk pengguna root Anda.

Untuk petunjuk, lihat [Mengaktifkan perangkat MFA virtual untuk pengguna root AWS akun \(konsol\) Anda di Panduan Pengguna IAM](#).

Saya perlu menginstal AWS CLI atau SDK AWS

Untuk menginstal AWS CLI, ikuti langkah-langkah di [Instal atau perbarui ke versi terbaru CLI AWS](#).

Untuk menginstal AWS SDK, pilih tab yang sesuai dengan bahasa pemrograman yang ingin Anda gunakan di [Tools to Build on AWS](#).

AWS kit pengembangan perangkat lunak (SDKs) tersedia untuk banyak bahasa pemrograman populer. Setiap SDK menyediakan API, contoh kode, dan dokumentasi yang memudahkan

pengembang untuk membangun aplikasi dalam bahasa pilihan mereka. SDKs secara otomatis melakukan tugas-tugas yang berguna untuk Anda, seperti:

- Tanda tangani permintaan layanan Anda secara kriptografis
- Permintaan coba lagi
- Menangani tanggapan kesalahan

Dapatkan kredensial untuk memberikan akses terprogram

Pengguna memerlukan akses terprogram jika mereka ingin berinteraksi dengan AWS di luar Konsol AWS Manajemen. Cara untuk memberikan akses terprogram tergantung pada jenis pengguna yang mengakses AWS.

Untuk memberi pengguna akses programatis, pilih salah satu opsi berikut.

Prinsipal mana yang membutuhkan akses terprogram?	Untuk	Oleh
Pengguna IAM:	Batasi durasi kredensial jangka panjang untuk menandatangani permintaan terprogram ke AWS CLI,, atau. AWS SDKs AWS APIs	Mengikuti petunjuk untuk antarmuka yang ingin Anda gunakan. • Untuk AWS CLI, lihat Mengautentikasi menggunakan kredensial pengguna IAM di Panduan Pengguna Antarmuka Baris Perintah.AWS • Untuk AWS SDKs dan alat, lihat Mengautentikasi menggunakan kredensial jangka panjang di Panduan Referensi Alat AWS SDKs dan Alat. • Untuk AWS APIs, lihat Mengelola kunci akses untuk pengguna IAM di Panduan Pengguna IAM.

Prinsipal mana yang membutuhkan akses terprogram?	Untuk	Oleh
Peran IAM	Gunakan kredensial sementara untuk menandatangani permintaan terprogram ke AWS CLI,, atau. AWS SDKs AWS APIs	Ikuti petunjuk di Menggunakan kredensial sementara dengan AWS sumber daya di Panduan Pengguna IAM.
Pengguna dikelola di Pusat Identitas IAM	Gunakan kredensial sementara untuk menandatangani permintaan terprogram ke AWS CLI,, atau. AWS SDKs AWS APIs	Mengikuti petunjuk untuk antarmuka yang ingin Anda gunakan. • Untuk AWS CLI, lihat Mengkonfigurasi CLI untuk menggunakan Pusat Identitas IAM di Panduan Pengguna Antarmuka Baris AWS Perintah. AWS • Untuk AWS SDKs, alat dan AWS APIs, lihat Autentikasi Pusat Identitas IAM di Panduan Referensi Alat AWS SDKs dan Alat.

Lampirkan izin Amazon Bedrock ke pengguna atau peran

Setelah menyiapkan kredensial untuk akses terprogram, Anda perlu mengonfigurasi izin untuk peran pengguna atau IAM agar memiliki akses ke tindakan terkait Amazon Bedrock. Untuk mengatur izin ini, lakukan hal berikut:

1. Pada halaman Beranda Konsol AWS Manajemen, pilih layanan IAM atau navigasikan ke konsol IAM di. <https://console.aws.amazon.com/iam/>
2. Pilih Pengguna atau Peran dan kemudian pilih pengguna atau peran Anda.
3. Di tab Izin, pilih Tambahkan izin, lalu pilih Tambahkan kebijakan AWS terkelola. Pilih kebijakan [AmazonBedrockFullAccess](#) AWS terkelola.

4. Untuk mengizinkan pengguna atau peran berlangganan model, pilih Buat kebijakan sebaris lalu tentukan izin berikut di editor JSON:

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

Hasilkan respons untuk prompt teks menggunakan model Amazon Nova

[Setelah memenuhi semua prasyarat, Anda dapat menguji pembuatan permintaan permintaan model ke model Amazon Nova dengan permintaan Converse.](#)

Untuk menginstal AWS CLI, ikuti langkah-langkah di [Instal atau perbarui ke versi terbaru CLI AWS](#). Verifikasi bahwa Anda telah menyiapkan kredensial Anda untuk menggunakan Boto3 dengan mengikuti langkah-langkah di [Dapatkan kredensial untuk memberikan akses terprogram](#)

Untuk menghasilkan respons untuk prompt teks di Nova 2 Lite dengan menggunakan AWS CLI, jalankan perintah berikut di terminal:

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

Inferensi inti

Inferensi adalah proses pengiriman permintaan ke model Amazon Nova dan menerima respons yang dihasilkan. Model Amazon Nova mendukung inferensi melalui dua opsi API:

- Converse API ([Converse](#), [ConverseStream](#)): Menyediakan antarmuka yang konsisten di berbagai model, membuatnya lebih mudah untuk beralih antar model atau membangun aplikasi yang bekerja dengan beberapa model. Direkomendasikan untuk sebagian besar kasus penggunaan.
- Invoke API ([InvokeModel](#), [InvokeModelWithResponseStream](#)): Muatan permintaan disusun secara khusus untuk format asli setiap model. Menjalankan inferensi menggunakan parameter prompt dan inferensi yang disediakan di badan permintaan.

Keduanya APIs mendukung fitur inti yang sama termasuk:

- Percakapan multi-giliran
- Masukan multimodal (teks, gambar, video, audio)
- Penggunaan alat
- Pagar pembatas
- Respons streaming

Struktur permintaan hampir identik antara keduanya APIs, hanya berbeda dalam cara data byte (dokumen, gambar, video dan audio) dikodekan. Untuk parameter permintaan model yang unik untuk model Amazon Nova, seperti `reasoningConfig` dan `topK`, ini ditempatkan dalam objek tambahan `inferenceConfig` di dalam file. `additionalModelRequestFields` Ini adalah parameter tingkat atas untuk `InvokeModel` dan `InvokeModelWithResponseStream`.

Note

Tinjau Sampel Kode dan Pemecahan Masalah untuk daftar sampel kode dengan model Nova 2.

Setel `modelId` ke salah satu dari berikut ini untuk menggunakan model Amazon Nova:

Model	ID Model
Nova 2 Lite	• global.amazon.nova-2-lite-v 1:0 • kami.amazon.nova-2-lite-v 1:0
Nova 2 Sonic	• global.amazon.nova-2-sonic-v 1:0 • kami.amazon.nova-2-sonic-v 1:0
Penyematan Multimodal Nova	amazon.nova-2- 1:0 multimodal-embeddings-v

Penting: Konfigurasi Batas Waktu

Important

Permintaan inferensi Amazon Nova dapat memakan waktu hingga 60 menit untuk diselesaikan. Konfigurasi pengaturan batas waktu klien Anda sesuai: Contoh berikut adalah kode Python. Pengguna dapat memeriksa dokumentasi untuk versi bahasa SDK pilihan mereka di dokumen API SDK tersebut.

```
from botocore.config import Config

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

Topik Inferensi Inti

Bagian ini membahas topik-topik berikut:

- Menggunakan API converse: Antarmuka konsisten yang menawarkan kompatibilitas di sebagian besar model Bedrock

- Menggunakan API pemanggilan: Antarmuka yang unik untuk model Nova dan tidak portabel ke model Bedrock lainnya
- Respons streaming: Pembuatan respons waktu nyata
- Menggunakan penyematan Amazon Nova: Kemampuan penyematan teks
- Inferensi sesuai permintaan: Pay-per-use model inferensi

Menggunakan Converse API

Converse API menyediakan antarmuka terpadu untuk berinteraksi dengan model Amazon Nova. Ini mengabstraksi detail spesifik model dan menyediakan cara yang konsisten untuk menangani percakapan multi-putaran, permintaan sistem, dan respons streaming di semua model Amazon Nova.

Topik

- [Struktur permintaan](#)
- [Menggunakan prompt sistem](#)
- [Parameter inferensi](#)
- [Menggunakan penalaran](#)

Struktur permintaan

- Percakapan multi-putaran: Pertahankan konteks di beberapa bursa
- Permintaan sistem: Instruksi sistem seperti persona atau pedoman respons
- Obrolan dokumen: Berinteraksi dengan dan meminta dokumen atau koleksi dokumen
- Visi: Memproses dan menganalisis gambar dan video
- Penggunaan alat: Aktifkan model untuk menggunakan alat eksternal dan APIs
- Pagar pembatas: Menerapkan pemfilteran konten dan kontrol keamanan
- Penalaran: Pemikiran yang diperluas untuk pemecahan masalah yang kompleks

Permintaan API Converse dasar mencakup ID model dan daftar pesan:

```
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)
```

Menggunakan prompt sistem

Permintaan sistem memberikan konteks dan instruksi untuk model:

```
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)
```

Parameter inferensi

Kontrol output model menggunakan parameter inferensi. Berikut ini adalah parameter inferensi yang tersedia.

- **MaxTokens (integer):** Jumlah maksimum token yang akan dihasilkan (hingga 65.000). Jika tidak ditentukan, model menggunakan default dinamis berdasarkan konteks permintaan.
- **suhu (mengambang):** Mengontrol keacakan (0,0-1,0, default 0,7). Nilai yang lebih rendah membuat output lebih deterministik
- **TopP (float):** Ambang pengambilan sampel nukleus (0-1, default 0,9). Nilai yang lebih rendah membuat output lebih fokus
- **stopSequences (array):** Urutan karakter yang menghentikan pembuatan saat ditemui

Contoh:

```
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)
```

Menggunakan penalaran

Nova 2 Lite mendukung pemikiran yang diperluas untuk pemecahan masalah yang kompleks. Aktifkan penalaran dengan `reasoningConfig`.

Secara default, penalaran dinonaktifkan untuk mengoptimalkan kecepatan dan biaya pada kueri sederhana. Ketika Anda perlu melampaui tugas-tugas sederhana ini, Anda dapat mengaktifkan penalaran. Nova 2 memberikan kontrol fleksibel atas kedalaman penalaran melalui tiga tingkat upaya:

Usaha rendah (`maxReasoningEffort: "low"`)

TERBAIK UNTUK: TUGAS DENGAN KOMPLEKSITAS TAMBAHAN YANG MEMBUTUHKAN PEMIKIRAN TERSTRUKTUR. Misalnya, Anda dapat menggunakan ini untuk tinjauan kode dan saran peningkatan di mana model perlu mempertimbangkan dengan cermat kualitas kode yang ada, tugas analisis yang memerlukan pertimbangan yang cermat dari berbagai faktor, atau skenario pemecahan masalah yang mendapat manfaat dari pendekatan metodis. Upaya rendah sangat ideal untuk tugas gabungan di mana penalaran dasar meningkatkan akurasi tanpa memerlukan perencanaan multi-langkah yang mendalam.

Upaya sedang (`maxReasoningEffort: "medium"`)

TERBAIK UNTUK: TUGAS MULTI-LANGKAH DAN ALUR KERJA PENGKODEAN. Misalnya, Anda dapat menggunakan ini untuk pengembangan perangkat lunak dan debugging di mana model perlu memahami struktur kode yang ada sebelum menerapkan perubahan, pembuatan kode yang memerlukan koordinasi di beberapa file atau komponen, perhitungan multi-langkah dengan saling ketergantungan, atau merencanakan tugas dengan beberapa kendala. Upaya sedang optimal untuk alur kerja agen yang mengoordinasikan beberapa alat dan memerlukan model untuk mempertahankan konteks di beberapa operasi berurutan.

Upaya tinggi (`maxReasoningEffort: "high"`)

TERBAIK UNTUK: MEMBENDUNG PENALARAN DAN PEMECAHAN MASALAH TINGKAT LANJUT. Misalnya, Anda dapat menggunakan ini untuk masalah matematika tingkat lanjut dan bukti yang memerlukan step-by-step verifikasi ketat, analisis ilmiah dan tugas penelitian yang menuntut penyelidikan mendalam, desain sistem yang kompleks dengan pertimbangan arsitektur di berbagai dimensi, atau skenario pengambilan keputusan kritis dengan implikasi signifikan. Upaya tinggi memberikan akurasi maksimum untuk tugas-tugas yang membutuhkan penalaran canggih, evaluasi alternatif yang cermat, dan validasi kesimpulan yang menyeluruh.

Contoh berikut menunjukkan tingkat upaya penalaran yang berbeda:

Low effort

```
import boto3

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

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

Parameter penalaran:

Berikut ini adalah parameter penalaran

- type: enabled atau disabled (default:disabled)
- maxReasoningEffort:low,medium, atauhigh. Ini diperlukan saat penalaran diaktifkan.

Note

Temperatur, TopP dan TopK tidak dapat digunakan dengan maxReasoningEffort set ke. high Ini akan menyebabkan kesalahan.

Tanggapan tersebut mencakup konten penalaran:

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

Note

Dengan Amazon Nova 2, konten penalaran ditampilkan sebagai [REDACTED]. Anda masih dikenakan biaya untuk penalaran token karena mereka berkontribusi pada peningkatan kualitas output. Kami menyertakan bidang ini dalam struktur respons sekarang untuk mempertahankan opsi mengekspos konten penalaran di masa depan. Kami secara aktif bekerja dengan pelanggan untuk menentukan pendekatan terbaik untuk memunculkan proses penalaran model.

Menggunakan API Invoke

API Invoke menyediakan akses langsung ke model Amazon Nova dengan lebih banyak kemampuan untuk mengontrol format permintaan dan respons. Tidak seperti API Converse yang mengabstraksi detail spesifik model, API Invoke memungkinkan Anda untuk bekerja secara langsung dengan struktur permintaan dan respons asli model.

 Note

Invoke API mendukung fitur yang sama dengan Converse API kecuali untuk modalitas input dokumen, yang khusus untuk Converse API.

Struktur permintaan

Permintaan API Invoke memerlukan ID model dan badan permintaan JSON:

```
import boto3
import json

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

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

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

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


Permintaan parameter

API Invoke mendukung parameter kunci berikut:

- **messages**: Array pesan percakapan dengan peran dan konten
- **system**: Permintaan sistem opsional untuk konteks dan instruksi
- **inferenceConfig**: Parameter yang mengontrol keluaran model (suhu, MaxTokens, TopP, TopK, StopSequences, ReasoningConfig)
- **toolConfig**: Spesifikasi alat dan pilihan alat untuk pemanggilan fungsi

Respons streaming

Streaming memungkinkan Anda menerima respons model secara bertahap saat dihasilkan, memberikan pengalaman pengguna yang lebih interaktif. Baik Converse API dan Invoke API mendukung streaming.

Streaming dengan ConverseStream

Gunakan ConverseStream untuk menerima tanggapan sebagai aliran acara:

```
import boto3

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

response = bedrock.converse_stream(
    modelId='us.amazon.nova-2-lite-v1:0',
    messages=[
        {
            'role': 'user',
            'content': [{'text': 'Write a short story about AI.'}]
        }
    ]
)

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

Streaming dengan InvokeModelWithResponseStream

Gunakan `InvokeModelWithResponseStream` untuk streaming dengan API `Invoke`:

```
import boto3
import json

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

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

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

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

Jenis acara streaming

Respons streaming mencakup beberapa jenis acara:

- `messageStart`: Menunjukkan awal pesan
- `contentBlockStart`: Menunjukkan awal dari blok konten
- `contentBlockDelta`: Berisi teks atau data tambahan
- `contentBlockStop`: Menunjukkan akhir dari blok konten
- `messageStop`: Menunjukkan akhir pesan dengan alasan berhenti
- `metadata`: Berisi informasi penggunaan (jumlah token)

Menggunakan penyematan Amazon Nova

Amazon Nova Multimodal Embeddings adalah model embeddings multimodal untuk RAG agen dan aplikasi pencarian semantik. Ini mendukung teks, dokumen, gambar, video dan audio melalui satu model, memungkinkan pengambilan lintas modal. Nova Multimodal Embeddings memetakan masing-masing jenis konten ini ke dalam ruang semantik terpadu, memungkinkan Anda untuk melakukan operasi vektor unimodal, lintas-modal, dan multimodal.

Ketika sepotong konten dilewatkan melalui penyematan Nova, model mengubah konten itu menjadi format numerik universal, yang disebut sebagai vektor. Vektor adalah seperangkat nilai numerik yang dapat digunakan untuk berbagai fungsi pencarian. Konten serupa diberikan vektor yang lebih dekat daripada konten yang kurang mirip.

Aplikasi:

- Pengambilan dan Rekomendasi Konten Semantik: Buat penyematan untuk konten Anda, lalu gunakan untuk menemukan item serupa atau memberikan rekomendasi yang dipersonalisasi.
- Pencarian Multimodal: Gabungkan penyematan dari berbagai jenis konten untuk mengaktifkan kemampuan pencarian lintas modal.
- RAG: Hasilkan penyematan dari konten multimodal seperti dokumen dengan teks dan gambar yang disisipkan untuk memberi daya pada alur kerja pengambilan Anda untuk aplikasi GenAI.

Fitur utama

Fitur-fitur utama ini membedakan Nova Embeddings:

- Support untuk teks, gambar, gambar dokumen, video, dan audio dalam ruang semantik terpadu. Panjang konteks maksimum adalah 8K token atau 30-an video dan 30-an audio.
- Sinkron dan asinkron APIs: API mendukung penggunaan sinkron dan asinkron.
- Segmentasi file besar: API async memudahkan untuk bekerja dengan input besar dengan menyediakan segmentasi yang dibangun API untuk teks panjang, video, dan audio, yang dikendalikan oleh parameter yang ditentukan pengguna. Model akan menghasilkan satu embedding untuk setiap segmen.
- Video dengan audio: Proses video dengan audio secara bersamaan. Tentukan apakah Anda ingin satu penyematan yang mewakili kedua modalitas atau dua penyematan terpisah.
- Tujuan penyematan: Optimalkan penyematan Anda tergantung pada aplikasi hilir yang dimaksud (retrieval/RAG/Search, klasifikasi, pengelompokan).

- Ukuran dimensi: 4 ukuran dimensi untuk menukar akurasi penyematan dan biaya penyimpanan vektor: 3072; 1024; 384; 256.
- Metode input: Lulus konten yang akan disematkan dengan menentukan URI S3 atau inline sebagai pengkodean base64.

Menghasilkan embeddings

Lengkapi yang berikut ini untuk menghasilkan embeddings.

Penyematan sinkron untuk teks:

```
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))
```

coba:

```
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))
```

Penyematan asinkron untuk video:

```
import boto3

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

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

```
#####'segmentationConfig': {
#####'durationSeconds': 15### Segment into 15 second chunks
#####},
#####},
####},
}
```

coba:

```
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'))
```

Inferensi Batch

Dengan inferensi batch, Anda dapat mengirimkan beberapa permintaan dan menghasilkan penyematan secara asinkron. Inferensi Batch membantu Anda memproses banyak permintaan secara efisien dengan mengirimkan satu permintaan dan menghasilkan respons dalam bucket Amazon S3.

- Setelah menentukan input model dalam file yang Anda buat, Anda mengunggah file ke bucket S3.
- Anda kemudian mengirimkan permintaan inferensi batch dan menentukan bucket S3.
- Setelah pekerjaan selesai, Anda dapat mengambil file output dari S3.
- Anda dapat menggunakan inferensi batch untuk meningkatkan kinerja inferensi model pada kumpulan data besar.

Format dan unggah data inferensi batch Anda

Anda harus menambahkan data inferensi batch ke lokasi S3 yang akan Anda pilih atau tentukan saat mengirimkan pekerjaan pemanggilan model. Lokasi S3 harus item berikut:

Setidaknya satu file JSONL yang mendefinisikan input model. Sebuah JSONL berisi baris objek JSON. File JSONL Anda harus diakhiri dengan ekstensi.jsonl dan dalam format berikut:

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

Jenis file masukan yang didukung

- Format Gambar: PNG, JPEG, WEBP, GIF
- Format Audio: MP3, WAV, OGG
- Format Video: MP4, MOV, MKV, WEBM, FLV, MPEG, MPG, WMV, 3GP

Inferensi sesuai permintaan

Inferensi sesuai permintaan menyediakan akses tanpa server ke model Amazon Nova tanpa memerlukan kapasitas yang disediakan. Mode ini secara otomatis menskalakan untuk menangani beban kerja dan biaya berdasarkan penggunaan.

Manfaat

Inferensi sesuai permintaan menawarkan beberapa keuntungan:

- Tidak ada perencanaan kapasitas: Secara otomatis skala untuk memenuhi permintaan
- Bayar per penggunaan: Hanya dikenakan biaya untuk token yang diproses
- Ketersediaan instan: Tidak diperlukan waktu penyediaan atau pemanasan
- Hemat biaya: Ideal untuk beban kerja variabel atau tidak terduga

Menggunakan inferensi sesuai permintaan

Inferensi sesuai permintaan adalah mode default untuk model Amazon Nova. Cukup tentukan ID model saat melakukan panggilan API:

```
import boto3

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

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

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

Harga

Inferensi sesuai permintaan ditagih berdasarkan jumlah token input dan output yang diproses. Untuk detail harga saat ini, lihat [harga Amazon Bedrock](#).

Kuota dan batas

Inferensi sesuai permintaan memiliki kuota default yang bervariasi menurut model dan wilayah. Untuk meminta peningkatan kuota, gunakan konsol [Service Quotas](#).

Menggunakan kemampuan Amazon Nova 2

Panduan ini memberikan resep berbasis tugas dan contoh praktis untuk membantu Anda mengintegrasikan kemampuan Nova ke dalam aplikasi Anda dengan cepat dan efektif. Ini dirancang untuk pengembang dan insinyur yang ingin:

- Integrasikan model Nova ke dalam aplikasinya melalui API
- Memahami persyaratan preprocessing dan strategi optimasi
- Menerapkan alur kerja pemahaman multimodal

Setiap bagian menyediakan:

- Informasi teknis utama tentang format yang didukung, batas ukuran, dan estimasi token
- Contoh kode yang menunjukkan cara menggunakan API dengan upload langsung dan Amazon S3
- Gunakan kasus yang menunjukkan aplikasi praktis
- Keterbatasan yang perlu dipertimbangkan saat mendesain aplikasi Anda

Prasyarat

Sebelum Anda mulai, pastikan Anda memiliki:

- A Akun AWS dengan akses ke Amazon Bedrock
- Izin IAM yang sesuai untuk memanggil model Bedrock
- AWS SDK diinstal (Boto3 untuk contoh Python)
- Keakraban dasar dengan AWS layanan, seperti Amazon S3 (untuk penanganan file besar)

Kemampuan penalaran

Amazon Nova 2 Lite mendukung pemikiran yang diperluas, yang dinonaktifkan secara default. Saat diaktifkan, model menghasilkan token penalaran internal yang meningkatkan kualitas respons. Di Amazon Nova 2 Lite, konten penalaran disunting dalam output dan ditampilkan sebagai [REDACTED], meskipun Anda masih dikenakan biaya untuk token ini.

Bidang penalaran disertakan dalam struktur respons untuk mempertahankan opsi mengekspos konten ini di rilis mendatang. Untuk informasi lebih lanjut tentang pemikiran yang diperluas, lihat [the section called “Pemikiran yang Diperpanjang”](#) dan [the section called “Pustaka kode”](#).

Pemahaman multimodal

Amazon Nova 2 Lite dapat memahami beberapa modalitas input. Model ini dilengkapi dengan kemampuan penglihatan yang memungkinkannya untuk memahami dan menganalisis gambar, dokumen, video, dan ucapan untuk menyimpulkan dan menjawab pertanyaan berdasarkan konten yang disediakan.

Bagian ini menguraikan pedoman untuk bekerja dengan gambar, dokumen, dan video di Amazon Nova termasuk strategi pra-pemrosesan yang digunakan, contoh kode, dan batasan yang relevan untuk dipertimbangkan.

Jenis konten yang didukung berdasarkan modalitas

Informasi berikut merinci format file yang didukung oleh setiap jenis file media dan metode input yang diterima.

Jenis file media	Format file yang didukung	Metode masukan	Keterbatasan ukuran	Jumlah objek
Citra	PNG, JPEG, GIF, WEBP	Menyematkan data dalam permintaan	25 MB	5
	Catatan: Jika Anda menggunakan file GIF atau WebP animasi, hanya bingkai pertama yang akan digunakan.	Jika Anda menggunakan Converse API, encode data sebagai byte. Jika Anda menggunakan API Invoke, encode data sebagai string Base64.		
		Amazon S3 URI	Total 2 GB	1000

Jenis file media	Format file yang didukung	Metode masukan	Keterbatasan ukuran	Jumlah objek
Video	MP4, MOV, MKV, WebM, FLV, MPEG, MPG, WMV, 3GP	Menyematkan data dalam permintaan	25 MB	1
		Jika Anda menggunakan Converse API, encode data sebagai byte. Jika Anda menggunakan API Invoke, encode data sebagai string Base64.		
		Amazon S3 URI	1 GB	1

Topik

- [Pemahaman gambar](#)
- [Pemahaman video](#)
- [Pemahaman dokumen](#)

Pemahaman gambar

Pemahaman gambar mengacu pada kemampuan Amazon Nova untuk memproses gambar dan melakukan berbagai tugas visi komputer seperti:

- Melakukan deteksi objek
- Menjawab pertanyaan tentang gambar melalui Visual Question Answering (VQA)
- Mengklasifikasikan dan meringkas gambar
- Melakukan deteksi kotak pembatas
- Pengenalan Karakter Optik (OCR)
- Penghitungan objek

Gambar dapat disertakan sebagai prompt yang diteruskan ke API sebagai array byte atau melalui URI S3.

Informasi teknis utama

Berikut ini adalah informasi teknis utama yang perlu diperhatikan ketika Anda bekerja dengan kemampuan ini.

Ukuran gambar dan penskalaan ulang

Amazon Nova secara otomatis mengubah skala gambar untuk mengoptimalkan kualitas dan kinerja:

- Menentukan rasio aspek terdekat (seperti 1:1, 1:2, 2:3 dan seterusnya)
- Rescales sehingga satu sisi ≥ 896 px atau cocok dengan sisi yang lebih pendek dari gambar asli—mana yang lebih besar
- Mempertahankan rasio aspek
- Mendukung resolusi hingga 8.000×8.000 px

Koordinat kotak pembatas:

- Berguna untuk tugas-tugas seperti mengidentifikasi elemen dalam tangkapan layar atau pentanahan gambar
- Koordinat dapat diubah skala agar sesuai dengan dimensi asli gambar dalam pasca-pemrosesan
- Mengembalikan kotak pembatas pada skala $[0, 1000]$.

Estimasi token gambar

Amazon Nova mengubah setiap gambar menjadi token untuk diproses. Jumlah token tergantung pada resolusi dan rasio aspek gambar.

Berikut ini adalah contoh perkiraan jumlah token berdasarkan resolusi gambar:

Resolusi gambar	Estimasi token
900 x 450	515
900 x 900	~1.035

Resolusi gambar	Estimasi token
1400 x 900	~ 1.600
1800 x 900	~ 2.060
1300 x 1300	~ 2.155

Contoh pemahaman gambar

Untuk contoh cara menyematkan data gambar secara langsung dalam permintaan, lihat input Multimodal menggunakan aset tertanam - Converse API (non-streaming) contoh di. [Pustaka kode](#)

Untuk mengunggah file gambar besar atau beberapa file gambar, di mana muatan keseluruhan lebih besar dari 25 MB, gunakan Amazon S3. Untuk contoh lengkap tentang cara menggunakan referensi Amazon S3 URI untuk input gambar, lihat contoh input Multimodal menggunakan S3 URI - Converse API (non-streaming) di contoh. [Pustaka kode](#)

Note

Saat menggunakan S3, pastikan layanan Amazon Bedrock memiliki izin untuk mengakses bucket dan objek.

Keterbatasan utama

Daftar berikut menguraikan batasan model pemahaman gambar saat ini:

- Pemahaman gambar multibahasa: Model memiliki pemahaman terbatas tentang gambar multibahasa dan bingkai video dan dapat berjuang atau berhalusinasi pada tugas-tugas sederhana.
- Identifikasi orang: Model Amazon Nova 2 tidak mendukung kemampuan untuk mengidentifikasi atau memberi nama individu dalam gambar, dokumen, atau video.
- Penalaran spasial: Model Amazon Nova 2 memiliki kemampuan penalaran spasial yang terbatas. Mereka mungkin berjuang dengan tugas-tugas yang membutuhkan lokalisasi atau analisis tata letak yang tepat.

- Teks kecil dalam gambar dan video: Jika teks dalam gambar atau video terlalu kecil, pertimbangkan untuk meningkatkan ukuran relatif teks dalam gambar dengan memotong ke bagian yang relevan sambil mempertahankan konteks yang diperlukan.

Pemahaman video

Pemahaman video mengacu pada kemampuan Amazon Nova untuk memproses input video dan melakukan berbagai tugas pemahaman video seperti:

- Menganalisis bingkai kunci dan meringkas konten video
- Menjawab pertanyaan tentang segmen video (Video Question Answering, atau Video QA)
- Mendeteksi dan melacak objek di seluruh bingkai
- Mengidentifikasi tindakan, adegan, dan peristiwa
- Melakukan segmentasi temporal untuk menemukan momen tertentu
- Menghasilkan keterangan deskriptif atau ringkasan urutan video

Informasi teknis utama

Berikut ini adalah informasi teknis utama yang perlu diperhatikan ketika Anda bekerja dengan kemampuan ini.

Informasi ukuran video

Kemampuan pemahaman video Amazon Nova mendukung rasio multi-aspek. Semua video diubah ukurannya dengan distorsi (naik atau turun, berdasarkan rasio aspek asli) hingga 672 × 672 dimensi persegi sebelum dimasukkan ke model.

Model ini menggunakan strategi pengambilan sampel dinamis berdasarkan panjang video. Untuk video berdurasi 16 menit atau kurang, Amazon Nova 2 Lite mengambil sampel 1 frame per detik (FPS). Untuk video yang berdurasi lebih dari 16 menit, laju pengambilan sampel menurun untuk mempertahankan sampel 960 frame yang konsisten, dengan laju pengambilan sampel bingkai bervariasi. Pendekatan ini dirancang untuk memberikan pemahaman video tingkat adegan yang lebih akurat untuk video yang lebih pendek dibandingkan dengan konten video yang lebih panjang.

Kami menyarankan Anda menjaga panjang video kurang dari 1 jam untuk gerakan rendah dan kurang dari 16 menit untuk apa pun dengan gerakan tinggi.

Seharusnya tidak ada perbedaan saat menganalisis versi video 4k dan versi Full HD. Demikian pula, karena laju pengambilan sampel adalah 1 FPS, video 60 FPS harus tampil sebaik video 30 FPS. Menggunakan resolusi dan FPS yang lebih tinggi dari yang dibutuhkan tidak menguntungkan karena batas 1 GB dalam ukuran video. Melakukannya akan membatasi panjang video yang sesuai dengan batas ukuran itu, jadi, Anda mungkin ingin melakukan pra-proses video lebih dari 1 GB.

Token video

Panjang video adalah faktor utama yang memengaruhi jumlah token yang dihasilkan. Untuk menghitung perkiraan biaya, kalikan perkiraan jumlah token video dengan harga per token untuk model tertentu yang digunakan.

Tabel berikut memberikan beberapa perkiraan pengambilan sampel bingkai dan pemanfaatan token per panjang video untuk Amazon Nova 2 Lite:

Panjang video	Bingkai untuk sampel	Tingkat sampel fps	Perkiraan token
10 detik	10	1	2,880
30 detik	30	1	8.640
16 menit	960	1	276,480
20 menit	1200	1	345.600
30 menit	1800	1	518.400
45 menit	2700	1	777.600

Contoh pemahaman video

Untuk contoh cara menyematkan data video secara langsung dalam permintaan, lihat input Multimodal menggunakan aset tertanam - Converse API (non-streaming) contoh di file. [Pustaka kode](#)

Untuk contoh cara menggunakan referensi URI S3 dalam input video, lihat input Multimodal menggunakan contoh S3 URI - Converse API (non-streaming) dalam contoh. [Pustaka kode](#)

Keterbatasan utama

Berikut ini adalah batasan model utama, di mana akurasi dan kinerja model mungkin tidak dijamin:

- Tidak ada dukungan audio: Model Amazon Nova saat ini dilatih untuk memproses dan memahami konten video hanya berdasarkan bingkai visual. Trek audio dalam video tidak diproses atau dianalisis.
- Pemahaman gambar multibahasa: Model Amazon Nova memiliki pemahaman terbatas tentang gambar multibahasa dan bingkai video. Mereka mungkin berjuang atau berhalusinasi pada tugas-tugas sederhana.
- Identifikasi orang: Model Amazon Nova tidak mendukung kemampuan untuk mengidentifikasi atau memberi nama individu dalam gambar, dokumen, atau video. Model tidak akan memberikan nama atau identitas orang dalam konten visual.
- Teks kecil dalam video: Jika teks dalam gambar atau video terlalu kecil, pertimbangkan untuk meningkatkan ukuran relatif teks dalam video.
- Penalaran spasial: Model Amazon Nova 2 memiliki kemampuan penalaran spasial yang terbatas. Mereka mungkin berjuang dengan tugas-tugas yang membutuhkan pemahaman yang tepat tentang posisi objek, jarak, atau hubungan spasial dalam video.
- Konten yang tidak pantas: Model Amazon Nova tidak akan memproses gambar yang tidak pantas atau eksplisit yang melanggar Kebijakan Penggunaan yang Dapat Diterima.
- Aplikasi perawatan kesehatan: Karena sifat sensitif dari artefak ini, meskipun model Amazon Nova dapat memberikan analisis umum pada beberapa gambar atau video perawatan kesehatan, kami tidak merekomendasikan penggunaannya untuk menafsirkan gambar medis sensitif seperti pemindaian diagnostik yang kompleks. Tanggapan model Amazon Nova tidak boleh dianggap sebagai pengganti nasihat medis profesional.

Pemahaman dokumen

Kemampuan pemahaman dokumen Amazon Nova memungkinkan Anda memasukkan seluruh dokumen (PDFs, file Word, spreadsheet, dan sebagainya) sebagai bagian dari prompt Anda. Hal ini memungkinkan model untuk menganalisis, meringkas, mengekstrak informasi dari, atau menjawab pertanyaan tentang konten dokumen.

Amazon Nova 2 Lite dapat menafsirkan teks dan elemen visual (seperti bagan atau tabel) dalam dokumen-dokumen ini. Ini memungkinkan kasus penggunaan seperti menjawab pertanyaan, meringkas, dan analisis laporan panjang atau dokumen yang dipindai.

Fitur pemahaman dokumen utama termasuk jendela konteks yang sangat besar (token 1M) untuk dokumen panjang dan kemampuan untuk menangani beberapa dokumen dalam satu kueri.

Modalitas dan format dokumen yang didukung

Amazon Nova membedakan antara dua jenis input dokumen:

- Dokumen berbasis teks, seperti file TXT, CSV, HTML, Markdown, atau DOC, diproses terutama untuk konten tekstualnya. Amazon Nova memahami dan mengekstrak informasi dari teks dalam dokumen-dokumen ini.
- Dokumen berbasis media, seperti file PDF atau DOCX, mungkin berisi tata letak kompleks, gambar, bagan, atau grafik tertanam. Untuk dokumen berbasis media, Amazon Nova menggunakan pemahaman berbasis visi untuk menafsirkan konten visual—seperti bagan, tabel, diagram, atau tangkapan layar—di samping teks dokumen.

Format file yang didukung mencakup jenis dokumen umum seperti:

- Teks biasa dan file teks terstruktur: CSV, TXT
- Spreadsheet: XLS, XLSX, HTML, Penurunan Harga
- Format gambar standar (untuk gambar dalam dokumen): PNG, JPG, GIF, WebP
- Format dokumen: DOC, DOCX, PDF
- PDFs yang berisi pengkodean gambar, seperti CMYK atau SVG tidak didukung.

Batas ukuran dokumen dan pedoman penggunaan

Kendala	Kuota
Jumlah dokumen maksimum	Hingga 5 dokumen per permintaan (berlaku untuk upload langsung dan Amazon S3)
Ukuran dokumen berbasis teks	Setiap dokumen teks harus sama dengan atau kurang dari 4,5 MB
Ukuran dokumen berbasis media	Untuk file PDF dan DOCX, tidak ada batasan ukuran file individual. Saat menggunakan upload langsung, ukuran gabungan semua dokumen media harus kurang atau sama dengan 25 MB. Saat menggunakan Amazon

Kendala

Kuota

S3, ukuran gabungan semua dokumen media harus kurang atau sama dengan 2 GB.

Konten PDF yang tidak didukung

PDFs yang berisi profil warna CMYK atau gambar SVG tidak didukung.

Harga

Amazon Nova menggunakan harga berbasis token: Anda membayar token input (semua yang Anda kirim, termasuk dokumen terlampir) dan token keluaran (respons model).

Memperkirakan token untuk PDFs: Untuk perencanaan, asumsikan halaman PDF standar 8,5x11 inci $\approx$ 2.560 token input (perkiraan ini mencakup elemen teks dan visual pada halaman biasa).

Contoh: Menggunakan pemahaman dokumen Nova melalui API dan S3

Untuk contoh cara menggunakannya melalui API, lihat input Multimodal menggunakan aset tertanam

- Converse API (non-streaming) contoh di. [Pustaka kode](#)

Untuk contoh cara menggunakannya melalui S3, lihat input Multimodal menggunakan contoh S3 URI

- Converse API (non-streaming) di. [Pustaka kode](#)

Speech-to-Speech (Amazon Nova 2 Sonic)

Amazon Nova 2 Sonic memungkinkan AI percakapan real-time dengan input dan output ucapan. Bagian berikut mencakup kemampuan canggih untuk membangun asisten suara interaktif, otomatisasi layanan pelanggan, dan aplikasi percakapan.

Fitur utama

Amazon Nova 2 Sonic menyediakan kemampuan berikut:

- State-of-the-art streaming pemahaman pidato dengan API streaming dua arah yang memungkinkan percakapan multi-putaran real-time dan latensi rendah.
- Dukungan multibahasa dengan deteksi dan peralihan bahasa otomatis. Suara ekspresif ditawarkan, termasuk suara yang terdengar maskulin dan suara feminin, dalam bahasa berikut:
 - Inggris (AS, Inggris, India, Australia)
 - Prancis
 - Bahasa Italia
 - Bahasa Jerman
 - Bahasa Spanyol
 - Bahasa Portugis
 - bahasa Hindi
- Suara Polyglot yang dapat berbicara dalam bahasa apa pun yang didukung untuk memungkinkan pengalaman pengguna yang konsisten bahkan ketika pengguna beralih bahasa dalam sesi yang sama.
- Kekokohan terhadap kebisingan latar belakang untuk skenario penyebaran dunia nyata.
- Kekokohan terhadap aksen yang berbeda untuk bahasa yang didukung.
- Pengalaman AI percakapan alami seperti manusia dengan kekayaan kontekstual di semua bahasa yang didukung.
- Respon ucapan adaptif yang secara dinamis menyesuaikan pengiriman berdasarkan prosodi pidato input.
- Pengambilan giliran cerdas yang mendeteksi kapan pengguna selesai berbicara dan kapan asisten harus merespons, menciptakan ritme dialog alami.
- Penanganan interupsi pengguna yang anggun tanpa menjatuhkan konteks percakapan.

- Pembedian pengetahuan dengan data perusahaan menggunakan Retrieval Augmented Generation (RAG).
- Panggilan fungsi dan dukungan alur kerja agen untuk membangun aplikasi AI yang kompleks.
- Penanganan alat asinkron yang mengeksekusi panggilan alat sambil mempertahankan alur percakapan, memungkinkan asisten untuk terus berbicara saat alat memproses di latar belakang.
- Dukungan input lintas modal untuk input audio dan teks dalam percakapan yang sama, memungkinkan pola interaksi yang fleksibel.
- Batas koneksi 8 menit, dengan pembaruan koneksi dan pola kelanjutan sesi tersedia dalam sampel kode.

Memulai dengan speech-to-speech

Bagian berikut memberikan contoh dan step-by-step penjelasan tentang cara menerapkan aplikasi streaming audio real-time yang sederhana menggunakan Amazon Nova 2 Sonic. Versi yang disederhanakan ini menunjukkan fungsionalitas inti yang diperlukan untuk membuat percakapan audio dengan model Amazon Nova 2 Sonic.

Anda dapat mengakses contoh berikut di [GitHubrepo sampel Nova](#) kami.

Ada batas koneksi 8 menit, dengan pembaruan koneksi dan pola kelanjutan percakapan tersedia di [GitHub](#)

Nyatakan impor dan konfigurasi

Bagian ini mengimpor pustaka yang diperlukan dan menetapkan parameter konfigurasi audio:

- `asyncio`: Untuk pemrograman asinkron
- `base64`: Untuk encoding dan decoding data audio
- `pyaudio`: Untuk pengambilan dan pemutaran audio
- Komponen Amazon Bedrock SDK untuk streaming
- Konstanta audio menentukan format pengambilan audio (laju sampel 16kHz, saluran mono)

```
import os
import asyncio
import base64
```

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

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

Tentukan **SimpleNovaSonic** kelas

SimpleNovaSonicKelas adalah kelas utama yang menangani interaksi Amazon Nova Sonic:

- `model_id`: ID model Amazon Nova Sonic () `amazon.nova-2-sonic-v1:0`
- `region`: AWS Wilayah, defaultnya adalah `us-east-1`
- Unik IDs untuk pelacakan cepat dan konten
- Antrian asinkron untuk pemutaran audio

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

Inisialisasi klien

Metode ini mengkonfigurasi klien Amazon Bedrock dengan yang berikut:

- Titik akhir yang sesuai untuk wilayah yang ditentukan
- Informasi otentikasi menggunakan variabel lingkungan untuk kredensial AWS
- Skema otentikasi SigV4 untuk panggilan API AWS

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

Menangani acara

Metode pembantu ini mengirimkan peristiwa JSON ke aliran dua arah, yang digunakan untuk semua komunikasi dengan model Amazon Nova Sonic:

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

Mulai sesi

Metode ini memulai sesi dan mengatur acara yang tersisa untuk memulai streaming audio. Peristiwa ini harus dikirim dalam urutan yang sama.

```
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())

```

Menangani input audio

Metode ini menangani siklus hidup input audio:

- `start_audio_input`: Mengkonfigurasi dan memulai aliran input audio
- `send_audio_chunk`: Mengkodekan dan mengirim potongan audio ke model
- `end_audio_input`: Menutup aliran input audio dengan benar

```

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)

```

Akhiri sesi

Metode ini menutup sesi dengan benar dengan:

- Mengirim promptEnd acara
- Mengirim sessionEnd acara
- Menutup aliran input

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

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

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

Menangani tanggapan

Metode ini terus memproses respons dari model dan melakukan hal berikut:

- Menunggu output dari aliran.

- Mem-parsing respons JSON.
- Menangani output teks dengan mencetak ke konsol dengan pengenalan suara dan transkripsi otomatis.
- Menangani output audio dengan decoding dan antrian untuk pemutaran.

```
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}")

```

Pemutaran audio

Metode ini akan melakukan tugas-tugas berikut:

- Menginisialisasi aliran PyAudio masukan
- Terus mengambil data audio dari antrian
- Memutar audio melalui speaker
- Membersihkan sumber daya dengan benar saat selesai

```

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

```

coba:

```

        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()
```

Tangkap audio

Metode ini akan melakukan tugas-tugas berikut:

- Menginisialisasi aliran PyAudio keluaran
- Memulai sesi input audio
- Terus menangkap potongan audio dari mikrofon
- Mengirim setiap potongan ke model Amazon Nova Sonic
- Membersihkan sumber daya dengan benar saat selesai

```
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()
```

coba:

```
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()
```

Jalankan fungsi utama

Fungsi utama mengatur seluruh proses dengan melakukan hal berikut:

- Membuat klien Amazon Nova 2 Sonic
- Memulai sesi
- Membuat tugas bersamaan untuk pemutaran dan pengambilan audio
- Menunggu pengguna menekan **Enter** untuk berhenti
- Mengakhiri sesi dengan benar dan membersihkan tugas

```
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())
```

Contoh kode

Contoh kode ini membantu Anda memulai Amazon Nova 2 Sonic dengan cepat. Anda dapat mengakses daftar lengkap contoh di halaman [GitHub sampel Amazon Nova Sonic](#).

Memulai contoh

Untuk contoh sederhana yang dirancang untuk membantu Anda mulai menggunakan Amazon Nova 2 Sonic, lihat implementasi berikut:

- [Implementasi dasar Amazon Nova 2 Sonic \(Python\)](#): Implementasi dasar yang menunjukkan bagaimana peristiwa disusun dalam API streaming dua arah. Versi ini tidak mendukung fungsionalitas tongkang (mengganggu asisten saat berbicara) dan tidak menerapkan komunikasi dua arah yang benar.
- [Implementasi Amazon Nova 2 Sonic berfitur lengkap \(Python\)](#): Implementasi berfitur lengkap dengan komunikasi dua arah nyata dan dukungan tongkang. Ini memungkinkan percakapan yang lebih alami di mana pengguna dapat mengganggu asisten saat berbicara, mirip dengan percakapan manusia.

- [Amazon Nova 2 Sonic dengan penggunaan alat \(Python\)](#): Implementasi lanjutan yang memperluas kemampuan komunikasi dua arah dengan contoh penggunaan alat. Versi ini menunjukkan bagaimana Amazon Nova 2 Sonic dapat berinteraksi dengan alat eksternal dan APIs untuk menyediakan fungsionalitas yang ditingkatkan.
- [Nova Sonic dengan teks dan Input campuran \(Python\)](#): Contoh implementasi untuk menampilkan bagaimana Amazon Nova 2 Sonic dapat memiliki teks sebagai input.
- [WebSocket Implementasi Java \(Java\)](#): Contoh ini mengimplementasikan aplikasi streaming audio WebSocket berbasis dua arah yang terintegrasi dengan Amazon Nova 2 Sonic untuk speech-to-speech percakapan real-time menggunakan Java.
- Implementasi [NodeJS Websocket \(NodeJS\)](#): Contoh ini mengimplementasikan aplikasi streaming audio berbasis WebSocket dua arah yang terintegrasi dengan Amazon Nova 2 Sonic untuk percakapan real-time menggunakan NodeJS. speech-to-speech
- [Implementasi NodeJS Websocket \(C #\)](#): Contoh ini mengimplementasikan aplikasi streaming audio WebSocket berbasis dua arah yang terintegrasi dengan Amazon Nova 2 Sonic untuk percakapan real-time menggunakan .NET. speech-to-speech

Kasus penggunaan lanjutan

Untuk contoh lanjutan yang menunjukkan kasus penggunaan yang lebih kompleks, lihat implementasi berikut:

- [Implementasi Amazon Bedrock Knowledge Base \(NodeJS\)](#): Contoh ini menunjukkan cara membangun aplikasi percakapan cerdas dengan mengintegrasikan Amazon Nova 2 Sonic dengan Amazon Bedrock Knowledge Base menggunakan NodeJS.
- [Manajemen Riwayat Obrolan \(Python\)](#): Contoh ini mencakup sistem pencatatan riwayat obrolan yang menangkap dan mempertahankan semua interaksi antara pengguna dan Amazon Nova 2 Sonic menggunakan Python.
- [Pembatalan Reservasi Hotel \(NodeJS\)](#): Contoh ini menunjukkan kasus penggunaan layanan pelanggan praktis untuk Amazon Nova 2 Sonic, menerapkan sistem pembatalan reservasi hotel menggunakan NodeJS.
- [LangChain Integrasi Basis Pengetahuan \(Python\)](#): Implementasi ini menunjukkan cara mengintegrasikan speech-to-speech kemampuan Amazon Nova 2 Sonic dengan basis pengetahuan yang LangChain didukung untuk meningkatkan pengalaman percakapan menggunakan Python.

- [Conversation Resumption \(NodeJS\)](#): Contoh ini menunjukkan bagaimana menerapkan kemampuan dimulainya kembali percakapan dengan Amazon Nova 2 Sonic. Menggunakan skenario pembatalan reservasi hotel sebagai konteksnya, aplikasi menunjukkan cara mempertahankan status percakapan di seluruh sesi, memungkinkan pengguna untuk melanjutkan interaksi yang sebelumnya terputus menggunakan NodeJS dengan mulus.
- [Nova 2 Sonic Speaks First \(NodeJS\)](#): Contoh ini menunjukkan bagaimana Amazon Nova 2 Sonic dapat memulai percakapan secara proaktif.
- [Session Continuation \(Python\)](#): Contoh ini menunjukkan cara mengaktifkan panjang percakapan tak terbatas dengan Amazon Nova 2 Sonic dengan menerapkan transisi sesi yang mulus. Aplikasi secara otomatis membuat dan beralih ke sesi baru di latar belakang, memungkinkan percakapan berlanjut tanpa batas waktu tanpa gangguan atau kehilangan konteks.

Bengkel langsung

Tersedia lokakarya langsung yang memandu Anda membangun aplikasi obrolan suara menggunakan Amazon Nova 2 Sonic dengan antarmuka streaming dua arah. Anda dapat [mengakses lokakarya](#) dan menemukan [contoh kode lengkapnya](#).

Permintaan percakapan suara

Nova 2 memperkenalkan Speech Prompts — kemampuan prompt khusus yang dirancang untuk mengontrol pemformatan transkripsi khusus ucapan untuk bahasa Hindi. Permintaan ucapan bekerja di samping prompt sistem Anda tetapi melayani tujuan yang berbeda:

- System Prompt: Mengontrol perilaku, kepribadian, dan gaya respons asisten Anda
- Speech Prompt: Mengontrol pemformatan transkripsi untuk pengalihan kode Hindi (skrip) Latin/Devanagari/mixed

Pedoman Penting

Permintaan ucapan sudah dikonfigurasi sebelumnya dan harus digunakan persis seperti yang didokumentasikan. Mereka dirancang untuk kebutuhan pemformatan transkripsi tertentu dan tidak boleh dimodifikasi atau disesuaikan, karena perubahan dapat menyebabkan perilaku yang tidak terduga.

Kapan menggunakan Speech Prompts:

- Anda perlu mengontrol output skrip untuk pengalihan kode Hindi () Latin/Devanagari/mixed

Kapan TIDAK menggunakan Speech Prompts:

- Untuk instruksi umum atau perilaku asisten (gunakan prompt sistem sebagai gantinya)
- Jika Anda tidak bekerja dengan format transkripsi Hindi
- Jika kebutuhan pemformatan tertentu tidak berlaku untuk kasus penggunaan Anda

Praktik Terbaik: Hanya sertakan prompt ucapan jika Anda secara khusus memerlukan pemformatan transkripsi Hindi. Semua instruksi lainnya — termasuk preferensi bahasa, gaya respons, verbositas, dan penalaran — harus masuk dalam prompt sistem Anda.

Penting: Permintaan ucapan harus dikirim setelah prompt sistem ke model.

Prompt Sistem Dasar yang Direkomendasikan untuk Suara

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.

Konfigurasi Speech Prompt

Pengalihan Kode

Catatan: Fitur ini saat ini hanya berlaku untuk bahasa Hindi.

Pilih salah satu petunjuk berikut berdasarkan skrip keluaran yang Anda inginkan:

Untuk keluaran skrip Latin (Hindi yang diromanisasi):

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

Untuk keluaran skrip Devanagari:

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

Untuk keluaran skrip campuran (pengalihan kode alami):

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

Konfigurasi Prompt Sistem

Mengontrol Verbositas Respon

Tanggapan percakapan yang ringkas:

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.

Tanggapan terperinci dan menyeluruh:

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.

Pencerminan Bahasa

Nova dapat mengenali dan merespons dalam bahasa yang digunakan pengguna. Gunakan prompt ini untuk menjaga konsistensi bahasa:

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.

Perjanjian Gender untuk Bahasa Gender

Beberapa bahasa memerlukan kesepakatan gender dalam kata kerja, kata sifat, atau kata ganti ketika asisten menggambarkan dirinya sendiri. Untuk bahasa-bahasa ini, tentukan jenis kelamin asisten di prompt sistem agar sesuai dengan suara yang Anda pilih.

Bahasa yang terpengaruh: Hindi, Portugis, Prancis, Italia, Spanyol, Rusia, Polandia

Ketika kesepakatan gender penting:

- Hindi: Selalu dibutuhkan - kata kerja konjugasi berdasarkan jenis kelamin pembicara sebagai orang pertama
- Portugis/Fransis: Diperlukan saat menggunakan partisipan atau kata sifat masa lalu (seperti, “Saya lelah” - “Estou cansada/cansado”)
- Italia/Spanyol: Diperlukan saat menggunakan kata sifat untuk menggambarkan diri sendiri (seperti, “Saya senang” - “Sono contenta/contento”)

Implementasi:

Sertakan pengenalan gender yang sesuai di awal prompt sistem Anda berdasarkan pilihan suara Anda:

Untuk suara yang terdengar feminin (kiara, carolina, ambre, beatrice, lupe, tiffany):

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

Untuk suara yang terdengar maskulin (arjun, leo, florian, lorenzo, carlos, matthew):

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

Contoh:

Hindi dengan suara feminin (kiara):

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

Hasil: “” (hoon achchhi utama) vs “” (hoon achchha utama)

Italia dengan suara maskulin (lorenzo):

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

Hasil: “Sono contento” vs “Sono contenta”

Rantai pemikiran untuk Pidato: Penalaran Konstitusional

Gunakan prompt ini saat Anda ingin model menunjukkan alasannya untuk masalah kompleks:

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.

Catatan: Jika Anda tidak ingin model melalui penalaran untuk setiap permintaan, Anda dapat menambahkan beberapa contoh bidikan ke prompt (lihat contoh di bawah).

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)

Terlalu sering menggunakan frasa yang disarankan

Nova Sonic 2 lebih sensitif terhadap saran frasa daripada Sonic 1. Sensitivitas yang meningkat ini pada dasarnya tidak baik atau buruk—itu tergantung pada kasus penggunaan Anda. Jika Anda menginginkan frasa yang konsisten dan dapat diprediksi, ini bisa bermanfaat. Namun, jika Anda menginginkan variasi yang lebih alami, daftar frasa eksplisit dapat menyebabkan penggunaan berlebihan.

Jika Anda menyertakan petunjuk dengan daftar frasa eksplisit, model akan sering menggunakannya:

Contoh 1 - Frase penekanan:

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."

Contoh 2 - Pengisi percakapan:

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.

Rekomendasi:

- Jika Anda ingin frasa yang konsisten: Daftar frasa eksplisit berfungsi dengan baik di Sonic 2 untuk menciptakan respons sesuai merek yang dapat diprediksi.
- Jika Anda menginginkan variasi alami: Hindari memberikan daftar frasa eksplisit. Sebagai gantinya, gunakan panduan umum seperti “terdengar alami dan percakapan” atau berikan contoh sekali pakai.

Pendekatan yang lebih baik - Gunakan contoh satu-shot:

Alih-alih mencantumkan frasa, berikan 1-2 contoh yang menunjukkan nada dan gaya yang diinginkan:

Nada alami dan bermanfaat

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.

Ringkas dan langsung

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

Example:

User: What's the weather like today?

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

Profesional dengan empati

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?

Teknis tetapi dapat diakses

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.


Pendekatan ini menunjukkan model perilaku yang diinginkan tanpa memicu pola frasa berulang, sambil tetap mempertahankan kontrol atas nada dan gaya.

Konsep inti

Amazon Nova 2 Sonic menggunakan arsitektur streaming dua arah dengan peristiwa terstruktur untuk AI percakapan waktu nyata. Memahami konsep inti ini sangat penting untuk membangun aplikasi suara yang efektif.

Siklus hidup acara

Diagram berikut menggambarkan siklus hidup acara streaming dua arah lengkap:



Siklus hidup acara streaming dua arah mengikuti pola terstruktur dari inisialisasi sesi hingga penyelesaian percakapan. Setiap percakapan melibatkan peristiwa masukan (dari aplikasi Anda) dan acara keluaran (dari Amazon Nova 2 Sonic) yang bekerja sama untuk menciptakan interaksi suara alami.

Urutan aliran acara

Percakapan khas mengikuti urutan acara ini:

1. Sesi Mulai - Inisialisasi sesi percakapan
2. System Prompt - Kirim instruksi sistem
3. Riwayat Obrolan (opsional) - Berikan konteks percakapan
4. Potongan Audio - Streaming input audio pengguna
5. Penyelesaian Mulai - AI mulai memproses
6. Transkrip ASR (USER) - Transkripsi ucapan pengguna
7. Penggunaan Alat (opsional) - AI meminta eksekusi alat
8. Penanganan Alat (opsional) - Proses dan kembalikan hasil alat
9. Transkrip (ASISTEN) - SPEKULATIF - Respons AI awal
10. Potongan Audio - Streaming output audio AI
11. Transkrip (ASISTEN) - FINAL - Transkrip respons AI akhir
12. Content End Audio - Menandai akhir konten audio
13. Prompt End - Menunjukkan penyelesaian pemrosesan prompt
14. Session End - Tutup percakapan

Menangani peristiwa masukan dengan API dua arah

API Stream dua arah menggunakan arsitektur berbasis peristiwa dengan peristiwa input dan output terstruktur. Memahami urutan acara yang benar sangat penting untuk menerapkan aplikasi percakapan yang sukses dan mempertahankan status percakapan yang tepat selama interaksi.

Ikhtisar

Percakapan Nova Sonic mengikuti urutan peristiwa terstruktur. Anda mulai dengan mengirimkan `sessionStart` peristiwa yang berisi parameter konfigurasi inferensi, seperti batas suhu dan token. Selanjutnya, Anda mengirim `promptStart` untuk menentukan format output audio dan konfigurasi

alat, menetapkan `promptName` pengidentifikasi unik yang harus disertakan dalam semua acara berikutnya.

Untuk setiap jenis interaksi (prompt sistem, audio, dan sebagainya), Anda mengikuti pola tiga bagian: gunakan `contentStart` untuk menentukan jenis konten dan peran konten (SYSTEM,,,SYSTEM_SPEECH) USER ASSISTANT TOOL, lalu berikan peristiwa konten yang sebenarnya, dan selesaikan dengan `contentEnd` untuk menutup segmen itu. `contentStartAcara` ini menentukan apakah Anda mengirim hasil alat, streaming audio, atau prompt sistem. `contentStartAcara` ini mencakup `contentName` pengenalan unik.

Riwayat Percakapan

Riwayat percakapan hanya dapat disertakan sekali, setelah prompt sistem dan sebelum streaming audio dimulai. Ini mengikuti `contentEnd` pola `contentStart/textInput` yang sama. ASSISTANT Peran USER dan harus didefinisikan dalam `contentStart` acara untuk setiap pesan sejarah. Ini memberikan konteks penting untuk percakapan saat ini tetapi harus diselesaikan sebelum masukan pengguna baru dimulai.

Streaming Audio

Streaming audio beroperasi dengan pengambilan sampel mikrofon kontinu. Setelah mengirim `inisiaccontentStart`, bingkai audio (masing-masing sekitar 32 ms) ditangkap langsung dari mikrofon dan segera dikirim sebagai `audioInput` acara menggunakan yang sama `contentName`. Sampel audio ini harus dialirkan secara real-time saat ditangkap, mempertahankan irama pengambilan sampel mikrofon alami selama percakapan. Semua bingkai audio berbagi satu wadah konten hingga percakapan berakhir dan ditutup secara eksplisit.


Menutup Sesi

Setelah percakapan berakhir atau perlu dihentikan, penting untuk menutup semua aliran terbuka dengan benar dan mengakhiri sesi dalam urutan yang benar. Untuk mengakhiri sesi dengan benar dan menghindari kebocoran sumber daya, Anda harus mengikuti urutan penutupan tertentu:

- Tutup semua aliran audio yang terbuka dengan `contentEnd` acara tersebut.
- Kirim `promptEnd` acara yang mereferensikan aslinya `promptName`.
- Kirim `sessionEnd` acara.

Melewatkan salah satu acara penutupan ini dapat mengakibatkan percakapan yang tidak lengkap atau sumber daya yatim piatu.

Pengidentifikasi ini membuat struktur hierarkis: `promptName` mengikat semua peristiwa percakapan bersama-sama, sementara masing-masing `contentName` menandai batas-batas blok konten tertentu. Hirarki ini memastikan bahwa model mempertahankan konteks yang tepat di seluruh interaksi.



Masukan Alur Acara

Struktur aliran peristiwa masukan disediakan di bagian ini.

1. RequestStartEvent (Sesi Mulai)

Acara mulai sesi menginisialisasi percakapan dengan konfigurasi inferensi dan mengubah pengaturan deteksi.

Konfigurasi inferensi:

- `maxTokens`: Jumlah maksimum token yang akan dihasilkan dalam respons
- `topP`: Parameter pengambilan sampel nukleus (0,0 hingga 1,0) untuk mengendalikan keacakan
- `temperature`: Mengontrol keacakan dalam generasi (0,0 hingga 1,0)

Turn Detection Configuration: `endpointingSensitivity` Parameter mengontrol seberapa cepat Nova Sonic mendeteksi ketika pengguna selesai berbicara:

- **HIGH:** Mendeteksi jeda dengan cepat, memungkinkan respons yang lebih cepat tetapi dapat memotong speaker yang lebih lambat
- **MEDIUM:** Sensitivitas seimbang untuk sebagian besar skenario percakapan (default yang disarankan)
- **LOW:** Menunggu lebih lama sebelum mendeteksi akhir pembicaraan, lebih baik untuk pembicara yang bijaksana atau ragu-ragu

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

Contoh:

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

2. PromptStartEvent

Acara mulai cepat mendefinisikan konfigurasi percakapan termasuk format output, pemilihan suara, dan alat yang tersedia.

Untuk daftar suara yang tersedia IDs, lihat [Dukungan bahasa dan kemampuan multibahasa](#)

```
{
  "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

Teks

Acara mulai konten teks digunakan untuk prompt sistem, riwayat percakapan, dan input teks lintas modal.

Parameter Interaktif:

- `true`: Mengaktifkan input lintas modal, memungkinkan pesan teks selama sesi suara aktif
- `false`: Input teks standar untuk permintaan sistem dan riwayat percakapan

Jenis Peran:

- `SYSTEM`: Instruksi dan petunjuk sistem
- `USER`: Pesan pengguna dalam riwayat percakapan atau input lintas modal
- `ASSISTANT`: Tanggapan asisten dalam riwayat percakapan
- `SYSTEM_SPEECH`: Mengontrol pemformatan transkripsi untuk pengalihan kode Hindi (skrip) Latin/Devanagari/mixed

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

Contoh - Prompt Sistem:

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

Contoh - Masukan Cross-modal:

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

Audio

```
{
  "event": {
    "contentStart": {
      "promptName": "string", // same unique identifier from promptStart event
      "contentName": "string", // unique identifier for the content block
      "type": "AUDIO",
      "interactive": true,
      "role": "USER",

```

```

        "audioInputConfiguration": {
            "mediaType": "audio/lpcm",
            "sampleRateHertz": 8000 | 16000 | 24000,
            "sampleSizeBits": 16,
            "channelCount": 1,
            "audioType": "SPEECH",
            "encoding": "base64"
        }
    }
}

```

Alat

```

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

```

4. TextInputContent

```

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

```

```
}
```

5. AudioInputContent

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

6. ToolResultContentEvent

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

7. InputContentEndEvent

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

8. PromptEndEvent

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

```
    }  
  }  
}
```

9. RequestEndEvent

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

Menangani peristiwa keluaran dengan API dua arah

Ketika model Amazon Nova Sonic merespons, ia mengikuti urutan peristiwa terstruktur. Alur dimulai dengan `completionStart` peristiwa yang berisi pengidentifikasi unik seperti `sessionId`, `promptName`, dan `completionId`. Pengidentifikasi ini konsisten sepanjang siklus respons dan menyatukan semua peristiwa respons berikutnya.

Ikhtisar

Setiap jenis respons mengikuti pola tiga bagian yang konsisten: `contentStart` mendefinisikan jenis dan format konten, peristiwa konten aktual, dan `contentEnd` menutup segmen tersebut. Respons biasanya mencakup beberapa blok konten secara berurutan: transkripsi pengenalan suara otomatis (ASR) (apa yang dikatakan pengguna), penggunaan alat opsional (ketika informasi eksternal diperlukan), respons teks (apa yang ingin dikatakan model), dan respons audio (keluaran lisan).

Jenis Konten Respons

Transkripsi ASR

Transkripsi ASR muncul pertama kali, memberikan pemahaman model tentang ucapan pengguna dengan `role: "USER"` dan `"additionalModelFields": "{\"generationStage\": \"FINAL\"}"` di `contentStart`

Penggunaan Alat

Ketika model membutuhkan data eksternal, ia mengirimkan peristiwa terkait alat dengan nama dan parameter alat tertentu.

Respon Teks

Respons teks memberikan pratinjau pidato yang direncanakan dengan `role: "ASSISTANT"` dan `"additionalModelFields": "{\"generationStage\":\"SPECULATIVE\"}"`.

Respon Audio

Respons audio kemudian memberikan potongan ucapan berencode base64 yang berbagi hal yang sama di seluruh aliran. `contentId`

Dukungan Barge-In

Selama pembuatan audio, Amazon Nova Sonic mendukung aliran percakapan alami melalui kemampuan tongkang. Ketika pengguna menyela Amazon Nova Sonic saat berbicara, Nova Sonic segera berhenti menghasilkan ucapan, beralih ke mode mendengarkan, dan mengirimkan pemberitahuan konten yang menunjukkan gangguan telah terjadi. Karena Nova Sonic beroperasi lebih cepat daripada waktu nyata, beberapa audio mungkin sudah dikirimkan tetapi belum diputar. Pemberitahuan interupsi memungkinkan aplikasi klien untuk menghapus antrian audionya dan segera menghentikan pemutaran, menciptakan pengalaman percakapan yang responsif.

Transkripsi Akhir

Setelah pembuatan audio selesai (atau terputus melalui tongkang), Amazon Nova Sonic memberikan respons teks tambahan yang berisi transkripsi tingkat kalimat dari apa yang sebenarnya diucapkan. Tanggapan teks ini mencakup `contentStart` acara dengan `role: "ASSISTANT"` dan `"additionalModelFields": "{\"generationStage\":\"FINAL\"}"`.

Pelacakan Penggunaan


Sepanjang penanganan respons, `usageEvent` acara dikirim untuk melacak konsumsi token. Peristiwa ini berisi metrik terperinci pada token input dan token keluaran (baik ucapan maupun teks), dan total kumulatifnya. Masing-masing `usageEvent` mempertahankan hal yang sama `sessionId`, `promptName`, dan `completionId` seperti peristiwa lain dalam aliran percakapan. Bagian detail menyediakan perubahan inkremental (delta) dan menjalankan total penggunaan token, memungkinkan pemantauan penggunaan yang tepat selama percakapan.

Penyelesaian

Model mengirimkan `completionEnd` acara dengan pengidentifikasi asli dan `stopReason` yang menunjukkan bagaimana percakapan berakhir. Hirarki peristiwa ini memastikan aplikasi Anda dapat

melacak bagian mana dari respons yang dimiliki bersama dan memprosesnya sesuai dengan itu, mempertahankan konteks percakapan di beberapa putaran.

Alur peristiwa keluaran dimulai dengan memasuki fase pembuatan respons. Dimulai dengan pengenalan suara otomatis, memilih alat untuk digunakan, mentranskripsikan ucapan, menghasilkan audio, menyelesaikan transkripsi, dan menyelesaikan sesi.



Aliran Acara Keluaran

Struktur aliran peristiwa keluaran dijelaskan di bagian ini.

1. UsageEvent

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

```

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

```

2. CompleteStartEvent

```

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

```

3. TextOutputContent

ContentStart

```

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

```



```
}
```

TextOutput

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

ContentEnd

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

4. ToolUse

ContentStart

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

```
}
}
```

ToolUse

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

ContentEnd

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

5. AudioOutputContent

ContentStart

```
"event": {
  "contentStart": {
    "sessionId": "string", // unique identifier
    "promptName": "string", // same unique identifier from promptStart event
    "completionId": "string", // unique identifier
    "contentId": "string", // unique identifier for the content block
    "type": "AUDIO",
    "role": "ASSISTANT",
```

```

    "audioOutputConfiguration": {
      "mediaType": "audio/lpcm",
      "sampleRateHertz": 8000 | 16000 | 24000,
      "sampleSizeBits": 16,
      "encoding": "base64",
      "channelCount": 1
    }
  }
}

```

AudioOutput

```

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

```

ContentEnd

```

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

```

6. CompletionEndEvent

```

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

```

```


    "stopReason": "END_TURN"
  }
}

```

Tongkang

Barge-in memungkinkan pengguna untuk mengganggu asisten AI saat berbicara, seperti dalam percakapan manusia alami. Alih-alih menunggu asisten selesai, pengguna dapat menyela dengan informasi baru, memperbaiki atau mengklarifikasi pernyataan mereka sebelumnya, mengarahkan percakapan ke topik yang berbeda, atau hanya menghentikan asisten ketika mereka sudah cukup mendengar. Ini menciptakan pengalaman percakapan yang lebih alami dan responsif.

Diagram berikut menggambarkan alur percakapan tongkang lengkap:



Bagaimana Amazon Nova 2 Sonic menangani tongkang

Amazon Nova 2 Sonic dirancang untuk menangani interupsi dengan anggun. Ketika pengguna mulai berbicara selama respons, sistem segera berhenti menghasilkan respons saat ini, mempertahankan konteks percakapan penuh, mengirimkan sinyal gangguan ke klien dan mulai memproses input pengguna baru.

Pelestarian Konteks: Bahkan ketika terputus, Nova Sonic mengingat apa yang dikatakan sebelum interupsi, topik yang sedang dibahas, riwayat percakapan dan konteks yang relevan dari giliran sebelumnya. Ini memastikan percakapan tetap koheren dan alami.

Persyaratan implementasi sisi klien

Sementara Amazon Nova 2 Sonic menangani tongkang di sisi server, Anda perlu menerapkan logika sisi klien untuk pengalaman yang lengkap.

Tantangan antrian audio: Pembuatan audio lebih cepat dari kecepatan pemutaran. Ini berarti:

- Nova Sonic menghasilkan potongan audio dengan cepat
- Klien Anda menerima dan mengantri potongan ini
- Klien memainkannya kembali dengan kecepatan berbicara normal
- Saat tongkang terjadi, sudah ada antrian audio untuk pemutaran

Logika sisi klien yang diperlukan: Aplikasi Anda harus menangani empat langkah utama:

1. **Deteksi Sinyal Gangguan:** Dengarkan peristiwa interupsi dari Nova Sonic dan segera bereaksi saat diterima.
2. **Hentikan Pemutaran Saat Ini:** Jeda audio yang sedang diputar dan hentikan audio apa pun yang sedang diputar di tengah pemutaran.
3. **Hapus Antrian Audio:** Hapus semua potongan audio yang diantri dan buang audio buffer apa pun dari respons yang terputus.
4. **Mulai Audio Baru:** Mulailah memutar audio yang baru diterima dan lanjutkan aliran pemutaran normal.

Kontrol pengambilan giliran

Turn-taking adalah aspek mendasar dari percakapan alami. Amazon Nova 2 Sonic memberikan kontrol halus tentang kapan AI mengambil giliran untuk berbicara melalui parameter. `turnDetectionConfiguration` Ini memungkinkan Anda untuk mengoptimalkan alur percakapan untuk berbagai kasus penggunaan, menyeimbangkan respons dengan akurasi. Parameter `EndpointingSensitivity` mengontrol seberapa cepat Amazon Nova 2 Sonic mendeteksi akhir giliran pengguna dan mulai merespons. Pengaturan ini memengaruhi latensi respons dan kemungkinan mengganggu pengguna yang masih berbicara.

Konfigurasi API

Konfigurasi sensitivitas deteksi giliran di acara SessionStart:

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

Tingkat sensitivitas

Parameter EndpointingSensitivity menerima tiga nilai: HIGH, MEDIUM, dan LOW. Setiap level menyeimbangkan kecepatan respons terhadap risiko mengganggu pengguna yang masih berbicara.

TINGGI

Waktu respons tercepat, dioptimalkan untuk latensi. Nova Sonic merespons secepat mungkin setelah mendeteksi akhir pembicaraan. Durasi jeda: 1,5 detik. Terbaik untuk Q dan A cepat, command-and-control aplikasi, dan interaksi sensitif waktu.

MEDIUM

Pendekatan seimbang dengan waktu respons moderat. Mengurangi positif palsu sambil mempertahankan daya tanggap. Durasi jeda: 1,75 detik. Terbaik untuk percakapan umum, layanan pelanggan dengan pertanyaan kompleks, dan diskusi multi-putaran.

RENDAH

Waktu respons paling lambat dengan kesabaran maksimal. Nova Sonic menunggu paling lama sebelum merespons, meminimalkan gangguan pengguna yang berhenti sejenak sambil berpikir. Durasi jeda: 2 detik. Terbaik untuk percakapan yang bijaksana, pengguna lansia atau gangguan bicara, dan pemecahan masalah yang kompleks.

Referensi durasi jeda

Tingkat sensitivitas	Durasi jeda (detik)
Tinggi (cepat)	1.5
Sedang	1,75
Rendah (lambat)	~ 2.0

Masukan lintas modal

Amazon Nova 2 Sonic sekarang mendukung input lintas modal, memungkinkan Anda mengirim pesan teks selain input suara selama sesi percakapan. Sementara ucapan tetap menjadi mode interaksi utama, input teks memberikan fleksibilitas untuk skenario di mana mengetik lebih nyaman atau sesuai.

Diperlukan streaming berkelanjutan: Input lintas modal memerlukan sesi streaming aktif agar berfungsi dengan baik. Sesi harus mempertahankan streaming berkelanjutan seperti sesi suara biasa, jika tidak, batas waktu sesi standar akan diterapkan dan koneksi akan dihentikan.

Tingkat sensitivitas dalam input teks lintas-modal berguna untuk skenario seperti:

- Integrasi aplikasi sisi klien (web dan seluler): Memungkinkan pengguna berinteraksi dengan aplikasi menggunakan teks dan suara, mendukung pengalaman multimodal yang mulus.
- Kasus penggunaan odel-start-first “M”: Pesan teks dapat dikirim segera setelah sesi mulai meminta model untuk mulai berbicara.
- Memandu model selama pemanggilan alat async: Ketika acara ToolUse dipicu dan sistem mulai memproses panggilan alat, klien dapat mengirim pesan teks ke Sonic untuk memberikan respons alami sambil menunggu — seperti, “Tunggu sebentar sementara saya memproses informasi Anda. Sementara itu, apakah ada hal lain yang bisa saya bantu?”
- Integrasi DTMF telepon: Pelanggan menggunakan keypad telepon untuk memasukkan informasi sensitif (seperti nomor kartu kredit). Catatan: Amazon Nova Sonic tidak memproses nada DTMF secara asli. Untuk mendukung input DTMF, sistem Anda harus mendeteksi nada, mengubahnya menjadi teks (seperti “1234”), dan mengirim ke Nova 2 Sonic.

Cara kerjanya

Input lintas modal menggunakan urutan tiga peristiwa yang mirip dengan input audio:

1. Acara Mulai Konten: Sinyal awal input teks
2. Acara Input Teks: Berisi pesan teks yang sebenarnya
3. Content End Event: Sinyal penyelesaian input teks

Ketiga peristiwa harus menggunakan PromptName dan contentName yang sama untuk mempertahankan urutan. UUID baru harus dibuat untuk ContentName setiap kali Anda mengirim input teks untuk memastikan pelacakan percakapan multi-putaran yang tepat.

Struktur peristiwa

1. Acara Mulai Konten

Memulai urutan input teks dengan detail konfigurasi:

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

Parameter kunci:

- **promptName**: Nama prompt percakapan Anda (konsisten di seluruh sesi)
- **contentName**: Pengidentifikasi unik untuk input teks ini (menghasilkan UUID baru untuk setiap pesan)
- **role**: Setel "USER" untuk menunjukkan masukan pengguna
- **type**: Setel ke "TEXT" untuk masukan teks

- `interactive`: Setel `true` untuk mengaktifkan mode interaktif
- `mediaType`: Setel ke `"text/plain"` untuk konten teks biasa

2. Acara Masukan Teks

Berisi konten pesan teks yang sebenarnya:

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

Parameter kunci:

- `promptName`: Harus cocok dengan nilai dari Acara Mulai Konten
- `contentName`: Harus cocok dengan nilai dari Acara Mulai Konten
- `role`: String pesan teks Anda

3. Acara Akhir Konten

Sinyal penyelesaian input teks:

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

Parameter kunci:

- `promptName`: Harus cocok dengan nilai dari peristiwa sebelumnya

- `contentName`: Harus cocok dengan nilai dari peristiwa sebelumnya

Dukungan bahasa dan kemampuan multibahasa

Amazon Nova 2 Sonic menyediakan beragam pilihan suara di berbagai bahasa, memungkinkan Anda membuat aplikasi AI percakapan yang terasa alami dan sesuai budaya bagi pengguna Anda. Setiap bahasa menawarkan pilihan suara yang terdengar feminin dan maskulin.

Tabel berikut mencantumkan semua suara yang tersedia dan bahasa lokal yang sesuai:

Bahasa	Lokal	ID Suara yang terdengar feminin	ID Suara yang terdengar maskulin
Inggris (US)	en-US	tiffany	matthew
Inggris (UK)	En-GB	amy	-
Inggris (Australia)	En-au	olivia	-
Inggris (India)	En-in	kiara	arjun
Prancis	FR-fr	ambre	florian
Bahasa Italia	It-itu	beatrice	lorenzo
Bahasa Jerman	De-de	tina	lennart
Spanyol (AS)	es-AS	lupe	carlos
Bahasa Portugis	Pt-BR	carolina	leo
bahasa Hindi	Hi-in	kiara	arjun

Struktur acara menggunakan suara dalam aplikasi Anda

Anda dapat menentukan ID suara di `audioOutputConfiguration` saat memulai prompt dalam `promptStart` acara:

```
"event": {
```

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

Dukungan multibahasa

Amazon Nova 2 Sonic menyediakan kemampuan multibahasa yang kuat yang memungkinkan percakapan alami di berbagai bahasa. Layanan ini mendukung suara polyglot (berbicara banyak bahasa) dan pengalihan kode (mencampur bahasa dalam kalimat yang sama), memungkinkan Anda untuk membangun aplikasi percakapan yang benar-benar global.

TIFFANY (en-US, perempuan) dan MATTHEW (en-US, laki-laki) adalah suara polyglot unik yang dapat berbicara semua bahasa yang didukung:

1. Bahasa Inggris
2. Prancis
3. Bahasa Italia
4. Bahasa Jerman
5. Bahasa Spanyol
6. Bahasa Portugis
7. bahasa Hindi

Ini membuat Tiffany dan Matthew ideal untuk aplikasi yang perlu beralih di antara beberapa bahasa dengan mulus.

Mengelola riwayat obrolan

Respons Amazon Nova 2 Sonic mencakup transkrip ASR (Automatic Speech Recognition) untuk suara pengguna dan asisten. Menyimpan riwayat obrolan adalah praktik terbaik—tidak hanya


untuk tujuan pencatatan tetapi juga untuk melanjutkan sesi ketika koneksi tiba-tiba ditutup. Hal ini memungkinkan klien untuk mengirim konteks kembali ke Nova Sonic untuk melanjutkan percakapan dengan mulus.

Lihat sumber daya berikut untuk informasi selengkapnya tentang mengelola riwayat obrolan:

1. [Mencatat riwayat obrolan](#)
2. [Melanjutkan percakapan](#)

Mengirim riwayat obrolan

Riwayat percakapan hanya dapat disertakan sekali, setelah prompt sistem/ucapan dan sebelum streaming audio dimulai. Riwayat obrolan keseluruhan tidak boleh lebih besar dari 40KB. Diagram berikut menunjukkan kapan riwayat obrolan diteruskan selama siklus hidup acara:



Setiap pesan sejarah membutuhkan tiga peristiwa: `contentStart`, `textInput` dan `contentEnd`.

Skema acara per pesan:

- `contentStart`- Mendefinisikan peran pesan dan konfigurasi

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

- `textInput`- Berisi konten pesan yang sebenarnya. Satu `TextInput` tidak boleh lebih besar dari 1KB. Jika demikian, bagi menjadi beberapa `TextInputs` di blok konten yang sama. Jika percakapan lebih besar dari 40KB, potong riwayat obrolan secara keseluruhan.

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

- `contentEnd`- Menandai akhir pesan

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

```
}  
}
```

Ulangi ketiga peristiwa ini untuk setiap pesan dalam riwayat obrolan Anda, bergantian antara peran USER dan ASSISTANT.

Pertimbangan penting:

- Riwayat obrolan hanya dapat disertakan sekali per sesi
- Riwayat obrolan harus dikirim setelah prompt sistem dan sebelum streaming audio dimulai
- Semua pesan historis harus dikirim sebelum memulai streaming audio
- Setiap pesan harus menentukan peran USER atau ASSISTANT
- Gunakan konten transkrip yang disimpan dari peristiwa TextOutput sebagai nilai konten di TextInput

Menerima transkrip ASR

Selama percakapan, Amazon Nova 2 Sonic mengirimkan transkrip ASR melalui acara keluaran. Setiap transkrip dikirimkan sebagai urutan dari tiga peristiwa: ContentStart, TextOutput, dan ContentEnd.

Contoh: Transkrip ucapan pengguna:

1. ContentStart - Menunjukkan awal transkrip:

```
{  
  "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 - Berisi konten transkrip yang sebenarnya:

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

3. ContentEnd - Menandai akhir transkrip:

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

Pola tiga peristiwa yang sama berlaku untuk peran USER dan ASSISTANT. Ekstrak content bidang dari textOutput acara dan role bidang dari contentStart acara untuk membangun riwayat obrolan Anda.

Praktik terbaik

Selalu simpan riwayat obrolan untuk mengaktifkan:

- Dimulainya kembali sesi di seluruh perangkat yang berbeda
- Pencatatan dan audit percakapan

- Pelestarian konteks untuk interaksi tindak lanjut

Penting: Saat menyimpan riwayat obrolan, gunakan output teks berdasarkan GenerationStage mereka:

- Spekulatif - Pratinjau dari apa yang direncanakan Nova 2 Sonic, dihasilkan sebelum sintesis audio dimulai
- Final - Transkripsi tingkat kalimat aktual dari apa yang diucapkan dalam respons audio

Selalu simpan output teks FINAL ke riwayat obrolan Anda, karena ini mewakili catatan percakapan yang akurat.

Contoh output FINAL (simpan ini ke riwayat obrolan):

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

Contoh output SPEKULATIF (pratinjau opsional, bukan untuk riwayat):

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

Konfigurasi alat

Amazon Nova 2 Sonic mendukung penggunaan alat (juga dikenal sebagai pemanggilan fungsi), memungkinkan model untuk meminta informasi atau tindakan eksternal selama percakapan, seperti panggilan API, kueri basis data, atau fungsi kode khusus. Ini memungkinkan asisten suara Anda


untuk mengambil tindakan, mengambil informasi, dan berintegrasi dengan layanan eksternal berdasarkan permintaan pengguna.

Nova 2 Sonic memiliki fitur panggilan alat asinkron, memungkinkan AI untuk terus berbicara secara alami sementara alat berjalan di latar belakang lain - menciptakan pengalaman pengguna yang lebih lancar dan responsif.

Berikut ini adalah langkah-langkah sederhana tentang cara menggunakan alat:

1. Tentukan alat: tentukan alat yang tersedia dengan parameteranya di acara PromptStart
2. Pengguna berbicara: pengguna membuat permintaan yang membutuhkan alat (seperti, "Bagaimana cuaca di Seattle?")
3. Pemanggilan alat: Nova 2 Sonic mengenali kebutuhan dan mengirimkan acara ToolUse
4. Jalankan rool: Aplikasi Anda mengeksekusi alat dan mengembalikan hasil
5. Generasi Respons: Nova 2 Sonic menggabungkan hasilnya ke dalam respons yang diucapkan

Diagram berikut menggambarkan cara kerja penggunaan alat:



Mendefinisikan alat

Alat didefinisikan menggunakan skema JSON yang menjelaskan tujuan, parameter, dan input yang diharapkan.

Berikut ini adalah komponen dan penjelasan definisi alat:

- Nama: Pengidentifikasi unik untuk alat (gunakan snake_case)
- Deskripsi: Penjelasan yang jelas tentang apa yang dilakukan alat; membantu AI memutuskan kapan menggunakannya
- InputSchema: Skema JSON yang mendefinisikan parameter yang diterima alat
- Properti: Parameter individu dengan jenis dan deskripsi
- Wajib: Array nama parameter yang harus disediakan

Contoh definisi alat

Berikut adalah definisi alat cuaca sederhana

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

```
}
```

Mengkonfigurasi Alat di PromptStart

Konfigurasi alat diteruskan ke Nova 2 Sonic dalam promptStart acara bersama dengan pengaturan output audio dan teks:

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

```

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

```

Parameter Pilihan Alat

Nova 2 Sonic mendukung tiga parameter pilihan alat untuk mengontrol kapan dan alat mana yang digunakan. Tentukan parameter ToolChoice dalam konfigurasi alat Anda:

- **Otomatis (default):** Model memutuskan apakah ada alat yang diperlukan dan dapat memanggil beberapa alat jika diperlukan. Memberikan fleksibilitas maksimum.
- **Apa saja:** Memastikan setidaknya satu alat yang tersedia dipanggil di awal respons, dengan model memilih yang paling tepat. Berguna ketika Anda memiliki banyak basis pengetahuan atau alat dan ingin menjamin satu digunakan.
- **Alat:** Memaksa alat bernama tertentu untuk dipanggil tepat sekali di awal respons. Misalnya, jika Anda menentukan alat basis pengetahuan, model akan menanyakannya sebelum merespons, terlepas dari apakah menurut alat tersebut diperlukan.

Contoh Pilihan Alat

Otomatis (default)

```

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

```

Apa saja:

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

Alat Khusus:

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

Menerima dan memproses acara penggunaan alat

Ketika Amazon Nova 2 Sonic menentukan bahwa alat diperlukan, ia mengirimkan `toolUse` acara yang berisi:

1. `toolUseID`: pengenalan unik untuk pemanggilan alat ini
2. `ToolName`: nama alat untuk mengeksekusi
3. `Konten`: String JSON yang berisi parameter yang diekstrak dari permintaan pengguna
4. `SessionId`: pengidentifikasi sesi saat ini
5. `Peran`: atur ke "ALAT" untuk acara penggunaan alat

Contoh acara penggunaan alat

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

```
    }  
  }  
}
```

Langkah-langkah pemrosesan

1. Terima acara ToolUse dari Nova 2 Sonic
2. Ekstrak nama alat dan parameter dari acara
3. Jalankan logika alat Anda (panggilan API, kueri basis data, dan sebagainya)
4. Kembalikan hasil menggunakan acara ToolResult

Contoh ToolResult Acara

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

Praktik terbaik

- Deskripsi yang jelas: Tulis deskripsi alat terperinci untuk membantu Nova 2 Sonic memahami kapan harus menggunakan setiap alat.
- Validasi parameter: Selalu validasi parameter alat sebelum eksekusi untuk mencegah kesalahan. Tentukan parameter alat menggunakan skema JSON yang tepat dengan tipe data terstruktur (seperti enum, angka, atau boolean) daripada string terbuka bila memungkinkan.
- Penanganan kesalahan: Kembalikan pesan kesalahan yang berarti dalam peristiwa ToolResult saat alat gagal.
- Eksekusi asinkron: Manfaatkan panggilan alat asinkron untuk mempertahankan alur percakapan.
- Penamaan alat: Gunakan nama deskriptif dan berorientasi tindakan (seperti `get_weather`, `search_database`, `send_email`).

Panggilan alat asinkron


Tidak seperti panggilan alat sinkron tradisional di mana AI menunggu diam-diam untuk hasil alat, pendekatan asinkron Amazon Nova 2 Sonic memungkinkannya untuk:

- Terus menerima masukan pengguna saat alat sedang berjalan
- Menanggapi pertanyaan baru tanpa menunggu hasil alat yang tertunda
- Menangani beberapa panggilan alat secara bersamaan
- Pertahankan aliran percakapan alami tanpa jeda yang canggung
- Tidak diperlukan konfigurasi tambahan. Pemanggilan alat asinkron bekerja di luar kotak.

Cara kerjanya

Ketika Nova 2 Sonic mengeluarkan panggilan alat, itu tidak menghentikan percakapan. Sebaliknya, ia terus mendengarkan dan merespons secara alami sampai alat tiba.


Asynchronous Tool Calling Flow



Menangani interupsi pengguna

Jika pengguna mengubah permintaan mereka saat alat dijalankan, Nova 2 Sonic menanganinya dengan cerdas tanpa membatalkan panggilan alat yang tertunda.

Async Tool Calling with User Interruption



Contoh skenario

```

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]
  
```

Cara kerjanya

Hasil alat selalu dikirimkan: Ketika panggilan alat selesai, hasilnya selalu dikirim ke model, bahkan jika pengguna telah mengubah permintaan mereka. Model menggunakan kemampuan penalarannya untuk menentukan bagaimana menangani informasi.

Pemrosesan sadar konteks: Model memahami konteks percakapan dan dapat menangani hasil alat yang sudah ketinggalan zaman dengan tepat. Contoh:

- Jika pengguna mengatakan “terima kasih” setelah berubah pikiran, model masih membutuhkan hasil asli untuk konteks
- Jika pengguna mengubah permintaan mereka, model dapat mengakui hasil asli sambil berfokus pada permintaan baru

Tidak ada pembatalan otomatis: Sistem tidak secara otomatis membatalkan atau mengabaikan panggilan alat berdasarkan input pengguna baru. Ini memastikan model memiliki informasi lengkap untuk membuat keputusan cerdas tentang bagaimana merespons.

Integrasi

Amazon Nova 2 Sonic dapat diintegrasikan dengan berbagai kerangka kerja dan platform untuk membangun aplikasi AI percakapan. Integrasi ini menyediakan komponen pra-bangun dan disederhanakan APIs untuk kasus penggunaan umum.

Agen Helai

Strands Agents adalah SDK sederhana namun kuat yang mengambil pendekatan berbasis model untuk membangun dan menjalankan agen AI. Dari asisten percakapan sederhana hingga alur kerja otonom yang kompleks, mulai dari pengembangan lokal hingga penyebaran produksi, Strands Agents menyesuaikan dengan kebutuhan Anda.

Untuk dokumentasi komprehensif tentang kerangka Strands, kunjungi [dokumentasi Strands resmi](#).

Strands BidiAgent menyediakan interaksi audio dan teks real-time melalui koneksi streaming persisten. Tidak seperti pola permintaan-respons tradisional, agen ini mempertahankan percakapan yang berjalan lama dengan dukungan untuk interupsi, pemrosesan bersamaan, dan respons audio berkelanjutan.

Prasyarat:

- Python 3.8 atau yang lebih baru diinstal
- Kredensial untuk AWS dikonfigurasi dengan akses ke Amazon Bedrock
- Keakraban dasar dengan sintaks Python async/await

Contoh kode:

Contoh kode

Instalasi:

Instal paket yang diperlukan:

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

Jalankan contoh ini:

```
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. Impor: Model yang Diperlukan

```

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:** Kelas agen utama yang mengatur percakapan dua arah
- **BidiAudioIO:** Menangani input dan output audio untuk interaksi ucapan
- **BidiTextIO:** Menyediakan output teks untuk transkripsi dan tanggapan
- **BidiNovaSonicModel** Pembungkus model Nova 2 Sonic
- **Kalkulator:** Alat pra-bangun untuk operasi matematika

2. Konfigurasi Audio dan Teks I/O

```

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

```

BidiAudioIO mengelola input mikrofon dan output speaker, sementara **BidiText IO** menampilkan transkripsi teks dan respons di konsol.

3. Inisialisasi Model

```

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

```

Buat contoh model Nova Sonic. Parameter wilayah menentukan AWS wilayah tempat model digunakan.

4. Buat dan Jalankan Agen

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

Agen dibuat dengan:

- Model: Model Nova 2 Sonic untuk digunakan
- Alat: Daftar alat yang dapat dipanggil agen (seperti kalkulator)
- Input: Input audio dari mikrofon
- Output: Output audio ke speaker dan output teks ke konsol


Integrasi kerangka kerja

Amazon Nova 2 Sonic dapat diintegrasikan dengan berbagai kerangka kerja dan platform untuk membangun aplikasi suara yang canggih. Contoh berikut menunjukkan pola integrasi dengan kerangka kerja populer.

Batuan Dasar Amazon AgentCore

Amazon Bedrock AgentCore menyediakan lingkungan runtime terkelola untuk menerapkan aplikasi Nova 2 Sonic dengan keamanan dan skalabilitas tingkat perusahaan. AgentCore menyederhanakan penerapan aplikasi AI suara real-time dengan menangani infrastruktur, otentikasi, dan konektivitas. WebSocket

AgentCore Architecture



Fitur utama:

- Streaming dua arah - Dukungan asli untuk antarmuka streaming dupleks penuh Nova Sonic dengan pemrosesan acara waktu nyata dan komunikasi latensi rendah.
- WebSocket infrastruktur - WebSocket Server siap produksi dengan penskalaan otomatis, manajemen koneksi, dan pemulihan kesalahan.
- Penyebaran kontainer - Menerapkan aplikasi Nova Sonic sebagai wadah ke infrastruktur terkelola dengan penskalaan horizontal dan versi independen.
- Keamanan perusahaan - Otentikasi halus melalui IAM dan SiGv4, isolasi VPC, dan pencatatan audit komprehensif.

Arsitektur menunjukkan bagaimana aplikasi klien terhubung ke AgentCore Runtime melalui WebSocket otentikasi SiGv4. Lingkungan kontainer mencakup WebSocket server Anda, logika aplikasi, dan klien Nova Sonic, semuanya berkomunikasi dengan Nova Sonic melalui API streaming dua arah.

Manfaat:

- Operasi yang disederhanakan: Fokus pada logika aplikasi sambil AgentCore mengelola infrastruktur, penskalaan, dan keandalan.
- Keamanan perusahaan: Fitur otentikasi, otorisasi, dan kepatuhan bawaan untuk penerapan produksi.
- Efisiensi biaya: Bayar hanya untuk apa yang Anda gunakan dengan penskalaan otomatis dan pengoptimalan sumber daya.
- Produktivitas pengembang: Kurangi waktu produksi dengan WebSocket infrastruktur terkelola dan penyebaran kontainer.

Kasus penggunaan


- Asisten suara layanan pelanggan dengan otentikasi aman
- Aplikasi suara perusahaan yang membutuhkan integrasi IAM
- Platform suara multi-penyewa dengan penyebaran terisolasi
- Aplikasi berkemampuan suara yang membutuhkan kepatuhan dan jalur audit

Untuk dokumentasi terperinci tentang penerapan Nova Sonic dengan AgentCore, kunjungi Dokumentasi [Amazon Bedrock AgentCore](#).

LiveKit

LiveKit adalah platform sumber terbuka untuk membangun aplikasi audio dan video real-time. Integrasi dengan Amazon Nova 2 Sonic memungkinkan pengembang untuk membangun antarmuka suara percakapan tanpa mengelola pipeline audio yang kompleks atau protokol pensinyalan.

Untuk contoh implementasi rinci dan contoh kode, kunjungi [Dokumentasi LiveKit AWS Integrasi](#).



Cara kerjanya:

- Lapisan klien: Aplikasi web, seluler, atau desktop terhubung menggunakan LiveKit klien SDKs, yang menangani pengambilan audio, streaming WebRTC, dan pemutaran.
- LiveKit Server: Bertindak sebagai pusat komunikasi real-time, mengelola koneksi WebRTC, merutekan aliran audio, dan menangani status sesi dengan optimasi latensi rendah.
- LiveKit Agen: Agen berbasis Python yang menerima audio dari server, memprosesnya melalui plugin Nova Sonic, dan mengalirkan respons kembali. Termasuk fitur bawaan seperti deteksi aktivitas suara dan manajemen belokan.
- Amazon Nova 2 Sonic: Memproses aliran audio melalui API streaming dua arah, melakukan pengenalan suara, pemahaman bahasa alami, dan menghasilkan respons percakapan dengan ucapan yang disintesis.


Pipecat

Pipecat adalah kerangka kerja untuk membangun aplikasi AI percakapan suara dan multimodal. Ini menyediakan arsitektur modular berbasis pipa yang mengatur beberapa komponen untuk membuat aplikasi suara cerdas dengan Amazon Nova Sonic dan layanan lainnya. AWS

Untuk contoh implementasi terperinci dan contoh kode, kunjungi [Dokumentasi PipeCat AWS Integrasi](#).

Fitur utama:

- Arsitektur pipa: Kerangka kerja berbasis Python modular untuk menyusun komponen AI suara termasuk ASR, NLU, TTS, dan banyak lagi.
- Aliran Pipecat: Kerangka kerja manajemen negara untuk membangun logika percakapan yang kompleks dan eksekusi alat.
- Dukungan WebRTC: Integrasi bawaan dengan penyedia WebRTC Harian dan lainnya untuk streaming audio real-time.
- AWS Integrasi: Dukungan asli untuk Amazon Bedrock, Amazon Transcribe, dan Amazon Polly.



Arsitekturnya meliputi:

- WebRTC Transport: Streaming audio real-time antara perangkat klien dan server aplikasi.
- Deteksi aktivitas suara (VAD): Silero VAD dengan deteksi suara yang dapat dikonfigurasi dan peredam bising.
- Pengenalan ucapan: Amazon Transcribe untuk konversi real-time speech-to-text yang akurat.
- Pemahaman bahasa alami: Amazon Nova Pro di Bedrock dengan inferensi yang dioptimalkan untuk latensi.
- Eksekusi alat: Aliran Pipecat untuk integrasi API dan panggilan layanan backend.
- Generasi respons: Amazon Nova Pro untuk respons yang koheren dan sadar konteks.
- Text-to-speech: Amazon Polly dengan suara generatif untuk keluaran ucapan yang hidup.


Menyebarkan pada AWS

Terapkan aplikasi Nova Sonic Anda untuk AWS menggunakan infrastruktur sebagai kode dengan AWS CDK (Cloud Development Kit). Pendekatan ini menyediakan penerapan yang dapat diulang dan dikendalikan versi dengan praktik terbaik bawaan.

Opsi deployment

- Amazon ECS (Elastic Container Service): Orkestrasi kontainer yang dikelola sepenuhnya dengan integrasi Application Load Balancer, auto-scaling, dan eksekusi Fargate tanpa server.
- Amazon EKS (Elastic Kubernetes Services): Kubernetes yang dikelola untuk orkestrasi kompleks, jaringan lanjutan, penerapan multi-wilayah, dan ekosistem perkakas yang luas.
- AWS CDK: AWS CDK memungkinkan Anda mendefinisikan infrastruktur cloud menggunakan bahasa pemrograman yang sudah dikenal.

[Untuk contoh lengkap yang siap produksi tentang penerapan Nova Sonic dengan AWS CDK, lihat Sampel CDK di \[Speech-to-Speech\]\(#\) GitHub](#) Sampel ini menunjukkan:



- Selesaikan pengaturan infrastruktur CDK dengan TypeScript
- WebSocket implementasi server untuk komunikasi real-time
- Penyebaran kontainer dengan ECS dan Fargate

- Konfigurasi Application Load Balancer untuk dukungan WebSocket
- Jaringan VPC dan pengaturan grup keamanan
- CloudWatch pemantauan dan pencatatan
- Praktik terbaik untuk penyebaran produksi

Sistem multi-agen

Arsitektur multi-agen adalah pola yang banyak digunakan untuk merancang asisten AI yang menangani tugas-tugas kompleks. Dalam asisten suara yang didukung oleh Nova 2 Sonic, arsitektur ini mengoordinasikan beberapa agen khusus, di mana setiap agen beroperasi secara independen untuk memungkinkan pemrosesan paralel, desain modular, dan solusi yang dapat diskalakan.

Nova Sonic berfungsi sebagai orkestrator dalam sistem multi-agen, melakukan dua fungsi utama:

Manajemen alur percakapan: Memastikan semua informasi yang diperlukan dikumpulkan sebelum melanjutkan ke langkah berikutnya dalam percakapan.

Klasifikasi maksud: Menganalisis pertanyaan pengguna dan merutekannya ke sub-agen khusus yang sesuai.




Diagram di atas menunjukkan asisten suara perbankan yang menggunakan arsitektur multi-agen. Alur percakapan dimulai dengan salam dan mengumpulkan nama pengguna, kemudian menangani pertanyaan terkait perbankan atau hipotek melalui sub-agen khusus.

Contoh alur percakapan:

1. Pengguna terhubung ke asisten suara.
2. Nova 2 Sonic: "Halo! Siapa namamu?"
3. Pengguna: "Nama saya John"
4. Nova 2 Sonic: "Hai John, bagaimana saya bisa membantu Anda hari ini?"
5. Pengguna: "Saya ingin memeriksa saldo akun saya"
6. Nova 2 Sonic: [Rute ke Agen Otentikasi]
7. Agen Otentikasi: "Harap berikan ID akun Anda"
8. Pengguna: "12345"
9. Agen Otentikasi: [Memverifikasi identitas]
10. Nova 2 Sonic: [Rute ke Agen Perbankan]

11 Agen Perbankan: "Saldo Anda saat ini adalah \$5.431,10"

Meskipun contoh ini menunjukkan sub-agen menggunakan kerangka Strands Agents yang diterapkan di Amazon Bedrock AgentCore, arsitekturnya fleksibel. Anda dapat memilih:

- Kerangka agen pilihan Anda
- Penyedia LLM mana pun
- Opsi hosting khusus
- Pola orkestrasi yang berbeda

Manfaat:

- Modularitas: Setiap agen berfokus pada domain tertentu, membuat sistem lebih mudah dirawat dan diperbarui.
- Skalabilitas: Tambahkan agen baru tanpa memodifikasi yang sudah ada, memungkinkan sistem Anda tumbuh sesuai kebutuhan Anda.
- Pemrosesan paralel: Beberapa agen dapat bekerja secara bersamaan, meningkatkan waktu respons untuk kueri yang kompleks.
- Spesialisasi: Setiap agen dapat dioptimalkan untuk tugas spesifiknya, menggunakan alat dan basis pengetahuan yang paling tepat.
- Isolasi kesalahan: Jika satu agen gagal, yang lain terus berfungsi, meningkatkan keandalan sistem secara keseluruhan.

Lihat [blog ini](#) untuk detail lebih lanjut dan contoh kode.

Lihat [Lab Multi-Agen Lokakarya Nova Sonic](#) untuk sampel langsung.

Integrasi telepon

Amazon Nova 2 Sonic terintegrasi dengan penyedia telepon untuk memungkinkan aplikasi suara bertenaga AI dapat diakses melalui panggilan telepon. Panduan ini mencakup integrasi dengan Twilio, Vonage, dan sistem berbasis SIP lainnya untuk membangun solusi pusat kontak dan agen suara.

Twilio: Platform komunikasi cloud dengan kemampuan streaming suara dan media yang dapat diprogram.

Vonage: Komunikasi global APIs dengan suara, streaming WebSocket audio, dan konektivitas SIP.

AWS menyediakan contoh implementasi komprehensif yang menunjukkan Nova Sonic di lingkungan pusat kontak dengan analisis real-time dan integrasi telepon.

Repositori: [Contoh Pusat Kontak Sonic dengan Telepon](#)

Sistem canggih dengan Amazon Nova

Ikhtisar

Bagian ini memberikan panduan komprehensif untuk pengguna daya yang menerapkan pola lanjutan dengan model Nova. Kemampuan ini memungkinkan aplikasi canggih termasuk integrasi alat, retrieval-augmented generation (RAG), dan agen AI otonom.

Pemikiran yang diperluas di Amazon Nova 2

Amazon Nova 2 Lite memperkenalkan kemampuan berpikir yang diperluas yang memungkinkan model untuk terlibat dalam penalaran yang lebih dalam untuk masalah yang kompleks. Fitur opsional ini memberi Anda kendali atas kapan dan bagaimana model mengalokasikan sumber daya komputasi tambahan untuk memikirkan tugas-tugas yang menantang.

Bagaimana Extended Thinking Bekerja

Amazon Nova 2 memperkenalkan pemikiran yang diperluas sebagai kemampuan hibrida. Anda memiliki kontrol penuh:

- Extended thinking OFF (default): Amazon Nova 2 beroperasi dengan penalaran laten yang efisien, optimal untuk tugas sehari-hari dan aplikasi volume tinggi.
- Pemikiran yang diperluas ON: Amazon Nova 2 terlibat dalam eksplisit, step-by-step penalaran terbaik untuk masalah kompleks yang membutuhkan analisis mendalam.

Upaya penalaran

Berikut ini menunjukkan berbagai tingkat upaya penalaran.

Upaya Rendah (MaxReasoningEffort: "rendah")

Terbaik untuk: Tugas dengan kompleksitas tambahan yang membutuhkan pemikiran terstruktur. Misalnya, Anda dapat menggunakan ini untuk tinjauan kode dan saran peningkatan di mana model perlu mempertimbangkan dengan cermat kualitas kode yang ada, tugas analisis yang memerlukan pertimbangan yang cermat dari berbagai faktor, atau skenario pemecahan masalah yang mendapat manfaat dari pendekatan metodis. Upaya rendah sangat ideal untuk tugas gabungan di mana

penalaran dasar meningkatkan akurasi tanpa memerlukan perencanaan multi-langkah yang mendalam.

Upaya sedang (maxReasoningEffort: “sedang”)

Terbaik untuk: Tugas multi-langkah dan alur kerja pengkodean. Misalnya, Anda dapat menggunakan ini untuk pengembangan perangkat lunak dan debugging di mana model perlu memahami struktur kode yang ada sebelum menerapkan perubahan, pembuatan kode yang memerlukan koordinasi di beberapa file atau komponen, perhitungan multi-langkah dengan saling ketergantungan, atau merencanakan tugas dengan beberapa kendala. Upaya sedang optimal untuk alur kerja agen yang mengoordinasikan beberapa alat dan memerlukan model untuk mempertahankan konteks di beberapa operasi berurutan.

Upaya Tinggi (MaxReasoningEffort: “tinggi”)

Terbaik untuk: Penalaran STEM dan pemecahan masalah tingkat lanjut. Misalnya, Anda dapat menggunakan ini untuk masalah matematika tingkat lanjut dan bukti yang memerlukan step-by-step verifikasi ketat, analisis ilmiah dan tugas penelitian yang menuntut penyelidikan mendalam, desain sistem yang kompleks dengan pertimbangan arsitektur di berbagai dimensi, atau skenario pengambilan keputusan kritis dengan implikasi signifikan. Upaya tinggi memberikan akurasi maksimum untuk tugas-tugas yang membutuhkan penalaran canggih, evaluasi alternatif yang cermat, dan validasi kesimpulan yang menyeluruh.

Mulai cepat: Mengaktifkan Berpikir Diperpanjang

Pemikiran yang diperluas dikendalikan melalui reasoningConfig parameter.

```
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"])

```

Parameter Penalaran:

- type: enabled atau disabled (default: disabled)
- maxReasoningEffort: low, medium, atau high

Note

Temperatur, TopP dan TopK tidak dapat digunakan dengan maxReasoningEffort set ke high. Menggunakan parameter ini bersama-sama menyebabkan kesalahan.

Untuk contoh lengkap kode yang menggunakan pemikiran yang diperluas, lihat [the section called “Pustaka kode”](#).

Struktur Respon

Saat Anda mengaktifkan pemikiran yang diperluas, respons menyertakan reasoningContent blok yang diikuti oleh blok text konten:

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

Note

Dengan Amazon Nova 2, konten penalaran ditampilkan sebagai [REDACTED]. Anda masih dikenakan biaya untuk penalaran token karena mereka berkontribusi pada peningkatan kualitas output. Kami menyertakan bidang ini dalam struktur respons sekarang untuk mempertahankan opsi mengekspos konten penalaran di masa depan. Kami secara aktif bekerja dengan pelanggan untuk menentukan pendekatan terbaik untuk memunculkan proses penalaran model. Konten penalaran ditampilkan sebagai [REDACTED]. Anda masih dikenakan biaya untuk token penalaran karena mereka berkontribusi pada peningkatan kualitas respons.

Opsi konfigurasi

Amazon Nova 2 memperkenalkan `reasoningConfig` parameter baru yang dapat Anda tambahkan ke struktur permintaan `converse` yang ada untuk mengaktifkan penalaran:

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

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

Parameter:

- **type**: Beralih antara "enabled" dan "disabled" (default adalah "disabled")
- **maxReasoningEffort**: Saat diaktifkan, kendalikan kedalaman penalaran
- "rendah": Tugas yang cukup kompleks
- "medium": Masalah kompleks yang membutuhkan analisis substansif
- "tinggi": Alasan paling menyeluruh untuk tugas yang sangat kompleks

Note

saat menggunakan "high", temp, TopP, dan maxToken harus tidak disetel. Dalam mode ini, model melakukan analisis yang lebih dalam untuk menemukan solusi terbaik. Pemrosesan yang lebih menyeluruh ini dapat menghasilkan output yang melebihi 65k token. Jumlah pastinya tergantung pada kompleksitas permintaan Anda, tetapi untuk beberapa masalah kami telah melihatnya naik menjadi 128K token. Ini memastikan Anda mendapatkan penalaran yang lengkap dan berkualitas tinggi daripada hasil yang terpotong.

Model yang didukung

Pemikiran yang diperluas saat ini tersedia di: Amazon Nova 2 Lite (us.amazon.nova-2-lite-v 1:0)

Pemikiran yang diperluas dengan penggunaan alat

Pemikiran yang diperluas bekerja dengan mulus dengan pemanggilan alat, memungkinkan Amazon Nova untuk bernalar tentang alat mana yang akan digunakan dan bagaimana menafsirkan hasilnya.

Memahami Token Penalaran dan Harga

Jenis token

Token pemikiran yang diperluas ditagih sebagai token keluaran:

- Token masukan: Konten permintaan asli Anda (harga input standar)
- Token keluaran: Ini termasuk token penalaran dan konten respons akhir yang terlihat (harga keluaran standar)

Kerusakan penggunaan

Ketiga jenis token disertakan dalam metrik penggunaan dan penagihan Anda. Token penalaran dihargai sama dengan token keluaran dan akan muncul sebagai “REDACTED” dalam respons model”.

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

Pertanyaan yang Sering Diajukan

Mengapa Amazon Nova 2 Lite menampilkan “[REDACTED]” untuk konten penalaran alih-alih menampilkan proses berpikir model?

Fokus utama kami untuk peluncuran ini adalah memastikan Nova 2 memberikan kecerdasan terbaik di kelasnya untuk tugas Anda, dan Anda akan melihat ini tercermin dalam akurasi yang ditingkatkan.

Kami menyadari bahwa visibilitas ke dalam proses penalaran sangat berharga, dan kami telah mendengar minat pelanggan yang kuat untuk memahami bagaimana model berpikir melalui masalah.

Kami sedang mencari cara untuk membuatnya segera tersedia.

Anda masih ditagih untuk token penalaran, karena mereka mewakili pekerjaan aktual yang meningkatkan kualitas output Anda

yang akan ditangkap outputTokens bersama dengan token jawaban.

Bagaimana saya tahu jika pemikiran yang diperluas berhasil jika penalaran disunting?

Anda dapat mengonfirmasi bahwa pemikiran yang diperluas berfungsi dengan memeriksa output untuk `reasoningContent` blok dalam respons (ini hanya muncul saat penalaran diaktifkan)

Menggunakan alat (panggilan fungsi)

Alat memperluas kemampuan Amazon Nova dengan menghubungkan model ke fungsionalitas eksternal seperti APIs, database dan lingkungan eksekusi kode. Penggunaan alat memungkinkan Amazon Nova mengakses informasi real-time, melakukan perhitungan, dan berinteraksi dengan sistem eksternal.

Memahami alur kerja penggunaan alat

Penggunaan alat dengan Amazon Nova melibatkan tiga fase utama:

Kueri Pengguna dan Definisi Alat

Tentukan alat dengan menyediakan skema JSON yang menjelaskan fungsionalitas masing-masing alat dan persyaratan input. Konfigurasi alat harus menyertakan detail eksplisit tentang kapan dan bagaimana menggunakan setiap alat.

Pemilihan Alat

Ketika pengguna mengirim pesan, Amazon Nova menganalisisnya untuk menentukan apakah alat diperlukan. Pilihan alat otomatis ini memeriksa konteks dan memutuskan alat mana (jika ada) untuk dipanggil. Jika Amazon Nova mengidentifikasi alat yang sesuai, ia mengembalikan nama alat dan parameter yang diperlukan.

Anda bertanggung jawab untuk mengeksekusi alat berdasarkan permintaan model. Ini berarti menulis kode yang memanggil fungsionalitas alat dan memproses parameter input yang disediakan oleh model.

Hasil Pengembalian

Setelah menjalankan alat, kirim hasilnya kembali ke Amazon Nova dalam format terstruktur menggunakan JSON atau kombinasi teks dan gambar. Amazon Nova menggabungkan output alat ke dalam respons akhir. Jika kesalahan terjadi selama eksekusi, nyatakan ini dalam respons alat untuk memungkinkan Amazon Nova menyesuaikannya.

Buat alat

Tentukan alat menggunakan konfigurasi alat yang mencakup berbagai alat dan secara opsional parameter pilihan alat. Setiap spesifikasi alat harus mencakup:

- Nama: Hapus pengenalan untuk alat
- Deskripsi: Penjelasan singkat tentang fungsionalitas alat
- Skema Input: Skema JSON yang mendefinisikan parameter yang diperlukan dan opsional

Example Contoh konfigurasi alat

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

Praktik terbaik untuk definisi alat

- Pastikan nama dan deskripsi secara eksplisit menyampaikan fungsionalitas alat yang tepat; hindari alat yang terlalu mirip secara semantik
- Sertakan pembeda utama dalam deskripsi untuk membantu model membedakan antara alat serupa

- Batasi skema JSON menjadi dua lapisan bersarang untuk kinerja terbaik
- Membatasi input menggunakan jenis skema (misalnya, enum, int, float) daripada menggambarkan struktur dalam teks biasa
- Nyatakan parameter yang diperlukan vs. opsional menggunakan notasi skema JSON (misalnya, "wajib": ["param1", "param2"])
- Validasi skema JSON Anda menggunakan validator standar sebelum mengirimkan
- Tempatkan argumen string panjang terakhir dalam skema dan hindari menyarakannya

Output terstruktur dengan decoding terbatas

Model Amazon Nova memanfaatkan decoding terbatas untuk memastikan keandalan tinggi dalam output yang dihasilkan. Teknik ini menggunakan tata bahasa untuk membatasi kemungkinan token pada setiap langkah pembuatan, mencegah kunci yang tidak valid dan menerapkan tipe data yang benar berdasarkan skema yang Anda tentukan.

Example Contoh keluaran terstruktur

```
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"}
}
}

```

Opsi pilihan alat

Amazon Nova mendukung tiga parameter pilihan alat:

Alat

Alat yang ditentukan akan dipanggil sekali, ideal untuk kasus penggunaan keluaran terstruktur

Setiap

Salah satu alat yang disediakan akan dipanggil setidaknya sekali, berguna untuk skenario pemilihan API

Otomatis

Model memutuskan apakah akan memanggil alat dan berapa banyak alat yang akan dipanggil (perilaku default)

Panggil alat

Ketika Amazon Nova memutuskan untuk memanggil alat, ia mengembalikan blok penggunaan alat sebagai bagian dari pesan asisten dengan StopReason disetel ke "tool_use". Blok alat berisi nama alat dan inputnya.

Note

Jalankan bagian kode berikut secara berurutan (Memanggil alat → Panggilan alat pemrosesan → Mengembalikan hasil alat) dalam satu sesi Python. Untuk menjalankan contoh lagi, restart sesi Python Anda.

Example Memanggil alat

```
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']}")

```

Panggilan alat pemrosesan

Ekstrak nama alat dan argumen dari pesan, lalu panggil alat:

```

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"])
```

Mengembalikan hasil alat

Kembalikan hasil alat menggunakan ToolResultBlock skema:

```
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}")
```

Penanganan kesalahan

Laporkan kesalahan kembali ke Amazon Nova untuk mengizinkan modifikasi permintaan dan coba lagi:

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

Pertimbangan keamanan

- Validasi bahwa alat ada sebelum memanggilnya
- Pastikan input diformat dengan benar
- Verifikasi izin yang sesuai ada sebelum eksekusi alat
- Andalkan detail sesi daripada mengizinkan Amazon Nova menyuntikkan informasi pengguna ke dalam panggilan alat
- Ingat bahwa LLMs dapat berhalusinasi panggilan alat; selalu memvalidasi sebelum eksekusi

Alat sistem bawaan

Model Amazon Nova 2.0 menyertakan alat bawaan yang dikelola sepenuhnya yang tidak memerlukan implementasi khusus. Aktifkan alat ini dengan sakelar sederhana di Converse API.

Penerjemah Kode

Code Interpreter memungkinkan Nova untuk menjalankan kode Python dengan aman di lingkungan kotak pasir yang terisolasi. Alat ini dirancang untuk perhitungan matematika, operasi logis, dan algoritma iteratif.

Note

Code Interpreter tersedia di Wilayah IAD, PDX, dan NRT. AWS Untuk memastikan permintaan Anda dialihkan ke Wilayah yang didukung, gunakan Global CRIS. Saat

menggunakan kunci API Bedrock, Anda harus menambahkan InvokeTool izin secara manual ke definisi kebijakan. Peran Bedrock default tidak mengizinkan InvokeTool tindakan.

Aktifkan Code Interpreter dengan menentukan parameter SystemTool:

```
import boto3
import json

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

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

response = bedrock.converse(
    modelId="us.amazon.nova-2-lite-v1:0",
    messages=[{
        "role": "user",
        "content": [{
            "text": "What is the average of 10, 24, 2, 3, 43, 52, 13, 68, 6, 7, 902,
82"
        }]
    }],
    toolConfig=tool_config,
    inferenceConfig={"maxTokens": 10000, "temperature": 0}
)

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

    elif "toolResult" in block:
        print("=== Tool Result ===")
        result = block['toolResult']['content'][0]['json']
```



```
print(f"Output: {result['stdOut']}")
if result['stdErr']:
    print(f"Error: {result['stdErr']}")
print(f"Exit Code: {result['exitCode']}\n")

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

Penerjemah menjalankan kode di kotak pasir dan mengembalikan hasil dalam skema standar:

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

Pembumian Web

Web grounding memungkinkan Amazon Nova untuk mengakses informasi real-time dari internet, memberikan up-to-date tanggapan dan mengurangi halusinasi. Aktifkan dengan menentukan alat sistem nova_grounding:

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

Untuk informasi rinci tentang Web Grounding, lihat [the section called “Pembumian Web”](#).

Protokol Konteks Model (MCP)

Model Context Protocol (MCP) adalah standar terbuka yang memungkinkan koneksi dua arah yang aman antara sumber data dan alat yang didukung AI. Alih-alih menulis adaptor khusus untuk setiap API atau layanan, jalankan server MCP dan biarkan Amazon Nova menemukan alatnya secara otomatis melalui jembatan klien.

Setelah terhubung, Amazon Nova memperlakukan alat MCP seperti integrasi eksternal lainnya: ia memutuskan kapan harus memanggil mereka, mengirim parameter yang diperlukan dan

memasukkan hasil ke dalam tanggapan. Menggunakan Amazon Nova dengan Strands membuatnya lebih mudah dengan built-in MCPClient yang mengelola penemuan, koneksi, dan pemetaan hasil secara otomatis.

Membangun agen AI

Model Amazon Nova dioptimalkan untuk membangun agen AI dengan Amazon Nova Act. Model menyediakan penggunaan alat yang ditingkatkan, penalaran yang lebih baik untuk tugas multi-langkah, peningkatan kemampuan untuk mempertahankan konteks di seluruh alur kerja agen yang kompleks dan dukungan untuk alat MCP jarak jauh.

Buat agen

Agen AI yang dibangun dengan Nova dapat mengatur beberapa panggilan alat, mempertahankan konteks di seluruh interaksi yang diperluas, dan mengoreksi kursus saat diperlukan. Pemikiran yang diperluas mengubah alur kerja agen dengan memungkinkan penalaran sistematis melalui tujuan yang kompleks. Pertimbangkan untuk menggunakan kerangka perencanaan SDK seperti Strands Agents untuk membuat proses perencanaan dan pelaksanaan sistem agen Anda lebih kuat.

Pola desain agen

Saat merancang agen dengan Nova:

- Aktifkan penalaran pada medium atau tinggi untuk hasil terbaik untuk alur kerja multi-langkah kompleks yang memerlukan perencanaan dan verifikasi
- Menerapkan pilihan alat auto untuk memungkinkan pemilihan alat yang fleksibel di seluruh interaksi agen
- Penanganan kesalahan desain yang memungkinkan agen memulihkan dan mencoba lagi dengan pendekatan yang dimodifikasi
- Pertahankan riwayat percakapan untuk mempertahankan konteks di seluruh interaksi agen
- Terapkan mekanisme pemfilteran dan moderasi konten yang kuat di seluruh konten yang tidak terkontrol yang dikonsumsi sistem agen Anda. Misalnya, Amazon menawarkan Amazon Bedrock Guardrails, fitur yang dirancang untuk menerapkan perlindungan di berbagai model pondasi, basis pengetahuan, dan agen. Pagar pembatas ini dapat menyaring konten berbahaya, memblokir topik yang ditolak, dan menyunting informasi sensitif seperti informasi yang dapat diidentifikasi secara pribadi.

Contoh agen multi-alat

```
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"
        #}
    #}
)

```

Meminta agen

Pemanggilan agen melibatkan pengelolaan alur percakapan, memproses panggilan alat, dan mempertahankan status di berbagai interaksi.

Tanggapan agen streaming

Streaming tanggapan untuk memberikan visibilitas real-time ke dalam penalaran dan tindakan agen:

```

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

```

```

        #"type": "enabled",
        #"maxReasoningEffort": "low"
    #}
#}
)

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

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

Final Architecture Design:
")

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

```

Manajemen negara agen

Pertahankan riwayat percakapan dan hasil alat untuk mempertahankan konteks; contoh di bawah ini menunjukkan ini untuk satu putaran, tetapi pengembang dapat menentukan cara mengatur sistem agen secara keseluruhan berdasarkan persyaratan alur kerja. Selain itu, alat Amazon Web Services seperti Strands mengelola konteks agen dan status alat atas nama pengembang.

```

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
    #)
```

Praktik Terbaik Agen

Untuk informasi selengkapnya tentang Praktik Terbaik Agen, lihat [the section called “Praktik terbaik”](#).

Untuk panduan mengembangkan agen AI Percakapan, lihat [Pidato ke Ucapan](#).

Pembumian Web

Web Grounding memungkinkan Amazon Nova untuk mencari web untuk informasi terkini dan memberikan tanggapan dengan kutipan. Fitur ini berguna untuk kueri yang membutuhkan up-to-date informasi di luar data pelatihan model.

Bagaimana Web Grounding bekerja

Ketika Web Grounding diaktifkan untuk prompt, langkah-langkah berikut dilakukan:

1. Minta Konfigurasi: Aplikasi Anda mengirimkan prompt pengguna ke Amazon Bedrock API dengan `nova_grounding` diaktifkan sebagai file. `systemTool`
2. Pencarian & Analisis: Model menentukan apakah pencarian diperlukan, melakukan satu atau lebih pencarian untuk informasi yang relevan, dan mengevaluasi apakah pencarian tambahan diperlukan untuk memperluas pemahamannya atau menyelam lebih dalam tentang subtopik tertentu.
3. Pembuatan respons: Amazon Nova secara otomatis mensintesis informasi dari hasil penelusuran untuk menghasilkan respons API akhir yang didasarkan pada informasi waktu nyata, lengkap dengan kutipan ke sumbernya.

Cara menggunakan Web Grounding

Untuk contoh lengkap kode yang menggunakan Web Grounding, lihat bagian Sampel Kode.

Untuk menyertakan Web Grounding dalam hasil Anda, tentukan `systemTool` parameter berikut di blok `ToolConfig` Anda:

```
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)
```

Ketersediaan wilayah

Web Grounding saat ini hanya tersedia di wilayah AS dan hanya didukung oleh profil CRIS AS.

Struktur respons

Berikut ini adalah contoh respons. Tanggapan telah dipersingkat untuk singkatnya:

```
{
```



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

Setiap kutipan meliputi:

- **text**: Segmen respons yang dihasilkan model.
- **citationsContent**: Wadah utama untuk data kutipan yang terkait dengan segmen teks.
- **citations**: Sebuah wadah di dalamnya **citationsContent** yang menyimpan lokasi kutipan.
- **location**: Sebuah wadah di dalamnya **citations** menyimpan sumber kutipan.
- **web**: Sebuah wadah di dalamnya **location** menyimpan detail sumber web.
- **url**: Alamat web lengkap (URL) dari sumber kutipan.
- **domain**: Domain root dari url sumber.

Keamanan grounding

Data Anda tidak pernah meninggalkan AWS infrastruktur. Kueri yang dihasilkan model tetap berada dalam AWS layanan dan tidak pernah dikirim ke internet yang lebih luas. Indeks pencarian web internal dan grafik pengetahuan kami yang luas memprioritaskan sumber yang dapat dipercaya dan berkualitas tinggi serta menyaring konten berbahaya saat masuk. Terakhir, kami melindungi aplikasi Anda dari injeksi prompt tidak langsung dan informasi yang salah dengan pemfilteran runtime (perhatikan bahwa mitigasi ini terbatas untuk bahasa non-Inggris).

Penanganan kesalahan

Jangan menyertakan toolSpec entri dengan namanova_grounding. Menyertakan alat dengan nama ini akan mengakibatkan kesalahan.

Berikut ini adalah daftar potensi kesalahan yang dapat terjadi saat menggunakan Web Grounding:

- malformed_tool_use
- max_tokens
- malformed_model_output

Izin diperlukan untuk alat bawaan

Untuk memastikan peran Anda dapat mengakses Web Grounding di Amazon Bedrock, Anda memiliki dua opsi:

1. BedrockFullAccess Aktifkan peran IAM Anda: Jika peran Anda memiliki BedrockFullAccess, itu akan memiliki akses otomatis ke Web Grounding.
2. Tambahkan Izin Khusus (jika diperlukan): Jika Anda memerlukan kontrol akses yang lebih terperinci, tambahkan kebijakan ini ke kebijakan IAM peran Anda, ganti ID akun dengan ID Anda: Akun AWS

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

Web Grounding memiliki kunci `aws:requestedRegion` kondisi yang disetel ke “tidak ditentukan”. Jika kebijakan yang ada atau Kebijakan Kontrol Layanan (SCPs) memberlakukan kondisi ini, Anda mungkin mengalami masalah akses. Memperbarui kondisi untuk mengizinkan `requestedRegion` “tidak ditentukan” dapat menyelesaikan masalah ini.

 Note

Jika Anda mengaktifkan alat Pembumian Web, Anda bertanggung jawab atas penggunaan Anda, dan penggunaan apa pun oleh pengguna akhir Anda, dari output yang menggabungkan informasi yang dibumikan. Anda akan tahu kapan output Anda menyertakan informasi yang dibumikan dari kutipan atau tautan ke materi sumber. Anda harus menyimpan dan menampilkan kutipan dan tautan ini dalam output yang Anda berikan kepada pengguna akhir Anda.

 Note

Web Grounding adalah biaya tambahan. Untuk informasi lebih lanjut, buka [harga AWS Bedrock](#).

Panduan rekayasa yang cepat

Teknik cepat adalah praktik merancang instruksi untuk berkomunikasi secara efektif dengan model bahasa besar (LLMs) seperti Amazon Nova. Rekayasa yang cepat memungkinkan Anda mengontrol perilaku model, meningkatkan kualitas output, dan membangun aplikasi bertenaga AI yang andal.

Rekayasa cepat yang efektif melibatkan masukan kerajinan yang memandu model untuk menghasilkan output yang diinginkan. Prompt yang dibuat dengan baik memberikan instruksi yang jelas, konteks yang relevan, dan data input yang diformat dengan benar.

Apa itu rekayasa cepat

Rekayasa cepat mengacu pada praktik mengoptimalkan input tekstual ke model bahasa besar (LLM) untuk meningkatkan output dan menerima tanggapan yang Anda inginkan. Meminta membantu LLM melakukan berbagai tugas, termasuk klasifikasi, menjawab pertanyaan, pembuatan kode, penulisan kreatif, dan banyak lagi. Kualitas petunjuk yang Anda berikan kepada LLM dapat memengaruhi kualitas respons model. Bagian ini memberi Anda informasi yang diperlukan untuk memulai dengan rekayasa yang cepat. Ini juga mencakup alat untuk membantu Anda menemukan format prompt terbaik untuk kasus penggunaan Anda saat menggunakan LLM di Amazon Bedrock.

Efektivitas petunjuk bergantung pada kualitas informasi yang diberikan dan keahlian prompt itu sendiri. Prompt dapat mencakup instruksi, pertanyaan, detail kontekstual, input, dan contoh untuk memandu model secara efektif dan meningkatkan kualitas hasil. Dokumen ini menguraikan strategi dan taktik untuk mengoptimalkan kinerja keluarga model Amazon Nova 2 Sonic. Metode yang disajikan di sini dapat digunakan dalam berbagai kombinasi untuk memperkuat efektivitasnya. Kami mendorong Anda untuk terlibat dalam eksperimen untuk mengidentifikasi pendekatan yang paling sesuai dengan kebutuhan spesifik mereka.

Memulai dengan rekayasa yang cepat

Sebelum Anda memulai rekayasa cepat, kami sarankan Anda memiliki elemen-elemen berikut, sehingga Anda dapat secara berulang mengembangkan prompt yang paling optimal untuk kasus penggunaan Anda:

Tentukan kasus penggunaan Anda

Tentukan kasus penggunaan Anda di empat dimensi:

- Tugas - Tentukan apa yang Anda ingin model capai. Ini menentukan teknik mendorong yang tepat.
- Peran — Tentukan peran apa yang harus diasumsikan oleh model untuk menyelesaikan tugas. Model Amazon Nova mendukung tiga peran (Sistem, Pengguna, atau Asisten).
- Response Style — Tentukan struktur respons atau gaya yang harus diikuti model berdasarkan audiens, seperti JSON, penurunan harga, atau percakapan.
- Instruksi — Tentukan serangkaian instruksi yang harus diikuti model untuk memenuhi kriteria keberhasilan.

Tetapkan kriteria keberhasilan

Tentukan kriteria keberhasilan atau metrik evaluasi. Anda dapat memberikan daftar kriteria atau memberikan metrik evaluasi khusus, seperti panjang, skor BLEU, ROUGE, format, faktualitas, dan kesetiaan.

Draf prompt

Buat prompt awal yang menggabungkan tugas, peran, gaya respons, dan instruksi Anda. Iterasi berdasarkan hasil.

Efektivitas petunjuk tergantung pada kualitas informasi yang Anda berikan.

Praktik terbaik umum

Praktik terbaik berikut terutama berlaku untuk model teks Amazon Nova, tetapi Anda dapat menerapkannya ke model lain, selain praktik terbaik khusus modalitas.

Untuk informasi lebih lanjut tentang cara meminta input multimodal, lihat. [Meminta input multimodal](#)

Untuk informasi tentang cara meminta input ucapan, lihat. [Permintaan percakapan suara](#)

Memahami peran

Model Amazon Nova memungkinkan Anda menyusun petunjuk melalui penggunaan tiga peran berbeda: sistem, pengguna, dan asisten.

- Sistem (opsional) — Meskipun tidak wajib, ini menetapkan parameter perilaku keseluruhan asisten. Ini juga dapat digunakan untuk memberikan instruksi dan pedoman tambahan bahwa pengguna ingin model untuk mematuhi selama percakapan.

- Pengguna — Secara opsional dapat menyampaikan konteks, tugas, instruksi, dan hasil yang diinginkan bersama dengan permintaan pengguna.
- Asisten — Membantu dalam membimbing model menuju respons yang diinginkan.

Topik

- [Buat petunjuk yang tepat](#)
- [Bawa fokus ke bagian prompt](#)
- [Menggunakan peran sistem](#)
- [Berikan contoh \(beberapa bidikan yang diminta\)](#)
- [Sistem panggilan alat](#)
- [Teknik meminta tingkat lanjut](#)

Buat petunjuk yang tepat

Membuat kueri pengguna tertentu sangat penting dalam rekayasa yang cepat. Kueri yang dibuat dengan baik mengarahkan model pemahaman teks Amazon Nova untuk menghasilkan respons yang akurat dan relevan. Untuk menyusun pertanyaan seperti itu, penting untuk memulai dengan memberikan informasi kontekstual dalam kueri. Konteks yang disediakan membantu menempatkan model lebih baik dengan menyelaraskan skenario target-pengguna yang jelas, sehingga meningkatkan relevansi dan koherensi output.

Memberikan informasi kontekstual dan spesifik

Model bekerja paling baik jika instruksinya jelas, terstruktur dengan baik, pendek, dan spesifik. Panduan template prompt ini berlaku untuk prompt pengguna dan prompt sistem.

Templat cepat

```
# 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}"""

```

Contoh: Informasi spesifik dan kontekstual

Berikut adalah contoh prompt yang ditulis ulang dengan informasi spesifik dan kontekstual.

Menambahkan lebih banyak informasi kontekstual membantu model landasan menuju perilaku yang diinginkan.

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]

- **Perjelas:** Saat mendorong model, cobalah untuk menjaga instruksi se jelas mungkin dengan cara yang akan dipahami manusia versus mesin (misalnya, daftar gaya JSON).
- **Jadilah spesifik:** Berikan instruksi spesifik model tentang apa tugasnya, apa output yang diharapkan, dan konteks tambahan apa pun untuk membantu model merespons seperti yang Anda inginkan.

Tentukan format dan gaya keluaran

Jika Anda ingin Amazon Nova 2 menghasilkan respons yang disesuaikan dengan kebutuhan spesifik Anda, Anda dapat menentukan format dan gaya output. Misalnya, jika Anda ingin menghasilkan respons hanya di JSON atau membatasi panjang respons ke jumlah kata, poin-poin, atau paragraf maksimum. Hal ini memungkinkan Amazon Nova 2 untuk lebih memahami kebutuhan Anda dan menghasilkan output yang lebih relevan dan lebih mudah untuk diuraikan.

Gunakan kapitalisasi dan kata-kata yang kuat seperti DO, JANGAN, HARUS untuk menekankan aturan yang Anda ingin model patuhi dengan ketat. Misalnya, jika Anda hanya menginginkan satu objek JSON dalam respons, Anda dapat menginstruksikan model dengan mengatakan “Anda HARUS menjawab dalam format JSON saja. Jangan gunakan format lain saat menjawab pertanyaan.”

Berikut adalah beberapa contoh petunjuk yang ditulis ulang dengan informasi spesifik dan kontekstual. Menambahkan lebih banyak informasi kontekstual membantu model landasan menuju perilaku yang diinginkan.

Contoh 1: Berikan detail tambahan

Menambahkan detail tambahan pada pemformatan respons dapat membantu model mencapai hasil yang diinginkan. Beberapa format respons lain yang umum digunakan termasuk CSV, Markdown, YANG, dan XML.

Prompt without style constraints

User:

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

Assistant:

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

1. **Standard Room**

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

2. **Deluxe Room**

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

- Access to a lounge or executive floor perks.

3. **Suite**

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

4. **Family Room**

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

5. **Executive Room**

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

6. **Junior Suite**

- **Size:** Usually around 450-600 square feet.
- **Features:**
 - Separate bedroom and living area.
 - King bed or two queen beds.
 - Kitchenette or mini-fridge.
 - Luxurious bathroom with a bathtub.
 - Lounge access.
 - High-end toiletries.

7. **Premium Room**

- **Size:** Larger than standard rooms, around 400-500 square feet.
- **Features:**

- King bed or two queen beds.
- Larger bathroom with a bathtub.
- Enhanced amenities like a welcome drink and premium toiletries.
- Access to premium services and sometimes a lounge.

8. **Connecting Rooms**

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

9. **Accessible Rooms**

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

10. **Business Room**

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

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

Prompt with style constraints

User:

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

Assistant:

```
```yaml
```

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

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

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

- room_type: Family Room
features:
- description: A spacious room designed for families with additional bedding
options.
amenities:
- bed_type: Queen bed and rollaway bed or two single beds and rollaway bed
```

```

- bathroom: Private bathroom with shower
- wifi: Complimentary high-speed internet
- TV: Flat-screen TV with cable channels
- mini_fridge: Available
- tea_and_coffee_making_facilities: Yes

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

```

## Contoh 2: Berikan batasan gaya

Dalam hal ini, prompt dengan batasan gaya memberikan informasi komprehensif tentang batasan yang harus diikuti dan format respons yang diinginkan. Seperti yang diamati dalam respons, prompt yang dioptimalkan lebih selaras dengan singkatnya yang diminta dan struktur daftar berpoin.

## 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.

### Contoh 3: Batasi format respons

Di sini, prompt dengan format respons memaksa model untuk merespons hanya dengan nomor kategori dan membatasinya menjadi antara 1-10, alih-alih sangat bertele-tele.

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

## Berikan bagian prompt yang jelas

Di luar konteks awal, format kueri terstruktur memainkan peran penting dalam mengoptimalkan interaksi dengan model bahasa. Memisahkan bagian input yang berbeda dengan pembatas memastikan kejelasan dan meningkatkan kemampuan model Amazon Nova 2 untuk memahami struktur kueri. Cara lain yang efektif adalah dengan menggunakan daftar bernomor atau poin-poin, yang dapat membantu memecah tugas menjadi langkah-langkah yang dapat dikelola dan memberikan garis besar yang jelas tentang tindakan yang perlu diambil. Pendekatan terstruktur ini membantu dalam mengurangi ambiguitas dan meningkatkan akurasi respons yang dihasilkan.

Contoh: Buat prompt yang dipotong

Perhatikan bagaimana di kolom Sectioned Prompt, prompt lebih jelas dan memiliki bagian yang digambarkan untuk entitas yang berbeda seperti Tugas, Konteks, Persyaratan, dan sisanya jika dibandingkan dengan instruksi di kolom Prompt Tidak Terpotong.

## 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.



## Bawa fokus ke bagian prompt

Model Amazon Nova 2 dapat memperhatikan bagian-bagian tertentu dalam prompt dengan memformat instruksi di bagian dan kemudian merujuk ke bagian tertentu tersebut. Model ini dapat memperhatikan jika petunjuk memiliki batasan penampang yang jelas menggunakan penurunan harga, XHTML, atau struktur lainnya. Misalnya, Anda dapat menentukan nama bagian, menggunakan `##Section Name##`, lalu merujuk ke bagian itu di prompt Anda dengan `##Section Name##`.

Anda juga dapat menggunakan strategi ini untuk membatasi model dari mengungkapkan bagian dari prompt input dalam respons yang dihasilkan. Misalnya, saat memberikan beberapa contoh atau instruksi bidikan dalam prompt input, gunakan pembatas seperti `##Instructions##` atau `##Examples##` dengan pemisah baris baru dan berikan instruksi yang kuat seperti `DO NOT mention anything inside the ##Instructions## or ##Examples## in the response` agar model tidak memuntahkan konten prompt input dari bagian ini dalam outputnya.

Contoh: Pembatasan bagian

Pengguna:

```
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##
```

## Menggunakan peran sistem

Peran Sistem adalah peran di mana Anda dapat memberikan instruksi kepada model yang menentukan bagaimana itu akan merespons pengguna akhir aplikasi Anda. Misalnya, Peran Sistem dapat memandu model untuk merespons dengan persona tertentu, mengatur konten yang diizinkan dan tidak diizinkan, output dalam format tertentu, menentukan pagar pembatas, dan sebagainya. Instruksi dalam Peran Sistem, yang disebut prompt sistem, akan menggantikan instruksi lain yang disediakan dalam permintaan pengguna individu, dan akan terbawa di semua giliran pengguna.

### Tentukan peran sistem dengan API

Untuk memberikan model peran yang disesuaikan, Anda dapat mengatur system parameter di API seperti di bawah ini:

```
{
 "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

- Untuk memanfaatkan peran sistem dengan sebaik-baiknya, pastikan bahwa prompt sistem Anda jelas, ringkas, dan spesifik, mengikuti strategi yang sama seperti yang dijelaskan dalam. [Buat petunjuk yang tepat](#) Misalnya, ketika Anda ingin membatasi topik yang harus ditanggapi oleh model, instruksikan secara khusus, seperti "JANGAN bicarakan... "atau" Anda HARUS berbicara tentang... ".
- Untuk lebih membatasi model ke struktur hierarki, Anda dapat menambahkan akhiran berikut ke prompt sistem Anda untuk menekankan struktur kepatuhan hierarki antara sistem dan instruksi pengguna:

```
"\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"
```

Item berikut adalah beberapa hal yang dapat Anda tambahkan dalam template prompt sistem:

```
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}
"""
```

Untuk memberikan perintah sistem struktur kepatuhan hierarki antara sistem dan instruksi pengguna, Anda dapat menambahkan yang berikut ini:

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.

Contoh 1: Memberikan isyarat bahasa tertentu

Setelah menambahkan prompt sistem, respons model sangat bergaya terhadap gaya gulir abad pertengahan seperti yang ditunjukkan dalam Prompt Sistem.

Without a System Prompt

Sistem:

NA

Pengguna:

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

Asisten:

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

### Sistem:

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

## Pengguna:

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

## Asisten:

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.

## Contoh 2: Menyediakan pagar pembatas

Dengan penambahan prompt sistem, pengguna dapat menambahkan pagar pembatas untuk aplikasi mereka untuk melindungi aplikasi untuk penggunaan yang tidak diinginkan. Berikut adalah contoh bagaimana pagar pembatas dapat memfokuskan model pada tugas yang diinginkan.

### Without a System Prompt

Sistem:

NA

Pengguna:

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.)

Asisten:

**\*\*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

### Sistem:

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

### Pengguna:

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.)

### Asisten:

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.

## Berikan contoh (beberapa bidikan yang diminta)

Dengan menyertakan beberapa contoh tugas Anda dalam prompt, Anda dapat membuat templat terstruktur untuk diikuti Amazon Nova 2. Ini mengurangi ambiguitas dan meningkatkan akurasi dan kualitas output. Teknik memberikan contoh yang jelas untuk membuat respons model lebih selaras dengan hasil yang diinginkan disebut prompt few-shot.

Konsep petunjuk beberapa tembakan adalah untuk memberikan model bahasa dengan beberapa contoh tugas, bersama dengan format input dan output, dan kemudian memintanya untuk menghasilkan output untuk input baru berdasarkan contoh yang diberikan. Metode ini juga membantu dalam mengklarifikasi instruksi atau tugas yang kompleks, sehingga memudahkan Amazon Nova 2 untuk memahami dan menafsirkan apa yang diminta.

Cara menambahkan contoh ke bantuan prompt:

Menambahkan contoh dapat membantu model memproduksi

- Respons konsisten yang seragam dengan gaya contoh
- Respons kinerja karena mengurangi kemungkinan salah menafsirkan instruksi, dan meminimalkan halusinasi

Jumlah peningkatan kinerja model menggunakan beberapa bidikan yang diminta akan bergantung pada kualitas dan keragaman contoh yang Anda pilih. Item berikut menunjukkan karakteristik bidikan yang baik dalam prompt:

- Pilih contoh yang beragam: Contoh yang dipilih harus mewakili distribusi yang Anda harapkan input/output dalam hal keragaman (mulai dari kasus penggunaan umum hingga kasus tepi) untuk mencakup kasus penggunaan yang relevan secara memadai. Penting untuk menghindari bias dalam contoh Anda, karena bias dalam input dapat menyebabkan output menjadi bias juga.
- Tingkat kompleksitas kecocokan: Kompleksitas contoh yang diberikan harus selaras dengan tugas atau skenario target. Penting untuk memastikan tingkat kompleksitas dipetakan antara input yang diharapkan dan contoh yang dipilih dalam prompt.
- Pastikan relevansi: Contoh yang dipilih harus secara langsung relevan dengan masalah atau tujuan yang dihadapi. Ini memastikan konsistensi dan keseragaman dalam tanggapan.

#### Tip

Jika saran di atas tidak berhasil, kami sarankan Anda membuat sistem berbasis RAG yang menambah prompt dengan pemilihan bidikan dinamis berdasarkan kesamaan antara kueri masukan pengguna dan kumpulan bidikan yang tersedia.

## Contoh 1: Berikan contoh di prompt pengguna

Di sini, pengguna Anda mencoba mengklasifikasikan tiket dukungan pelanggan yang masuk ke dalam kategori yang telah ditentukan. Anda dapat memberikan model Amazon Nova 2 dengan beberapa contoh tiket yang diklasifikasikan dengan benar untuk meningkatkan pemahamannya tentang kategori dan bahasa yang digunakan dalam tiket. Exemplar examples harus ringkas dan mewakili semua tugas yang ditargetkan dalam aplikasi Anda. Jika ada nama bidang tertentu yang berarti untuk tugas, seperti Ticket atau Category dalam contoh ini, pengguna Anda dapat menggunakan bidang tersebut secara langsung diikuti oleh titik dua ":".

### 0-shot prompt

Pengguna:

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."

Asisten:

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

Pengguna:

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."

Asisten:

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.

## Contoh 2: Memberikan contoh sebagai prompt giliran

Dalam contoh ini, contoh disediakan sebagai belokan, satu putaran per contoh, di mana peran berisi input dan User Assistant peran berisi output yang diharapkan untuk contoh itu.

### 0-shot Prompt

Sistem:

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

Categories:

- Food
- Entertainment
- Health
- Wealth
- Other

Pengguna:

I have 20\$ in my pocket.

Asisten:

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)

Sistem:

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

Categories:

- Food
- Entertainment
- Health
- Wealth
- Other

Pengguna:

I love to eat pizza.

Asisten:

Food

Pengguna:

I enjoy watching movies.

Asisten:

Entertainment

Pengguna:

I am going to the gym after this.

Asisten:

Health

Pengguna:

I have 20\$ in my pocket.

Asisten:

Wealth

### Contoh 3: Memberikan contoh dalam prompt sistem

Dalam contoh ini, Anda dapat menentukan bagian “Contoh” dan kemudian daftar serangkaian contoh dalam prompt sistem. Cara memberikan contoh dalam prompt ini sangat berguna jika contoh Anda panjang dan kompleks dan membantu model menemukan contoh bidikan.

### 0-shot Prompt

Sistem:

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.

Pengguna:

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

Asisten:

# 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

### Sistem:

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]

Pengguna:

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

Asisten:

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

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

<hr>

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

- Successfully completed the implementation of the new enterprise resource planning (ERP) system.<br>
- Conducted and completed the first phase of the data migration process.<br>

- Successfully launched the new inventory management module.

**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.

## Sistem panggilan alat

Panggilan alat tersedia untuk model Amazon Nova dengan meneruskan skema konfigurasi alat dalam permintaan Anda. Prompt untuk model akan ditambah dengan konfigurasi alat ini sehingga ini adalah tempat yang sangat berdampak untuk mulai mengoptimalkan sistem pemanggilan alat Anda.

Pertimbangkan prinsip-prinsip utama ini:

- Definisi alat harus jelas dan ringkas. Mereka harus mudah dipahami dan niatnya harus sangat jelas.

- Gunakan pembeda kunci dan kondisi batas untuk menentukan kapan satu alat harus digunakan di atas yang lain.
- Jadilah kritis jenis argumen masukan. Tanyakan, apakah mereka masuk akal dan apakah mereka diharapkan untuk digunakan dengan cara itu secara normal?

Gunakan “Tool Choice” untuk mengontrol kapan alat dipanggil

Parameter pilihan alat memungkinkan Anda untuk menyesuaikan perilaku pemanggilan alat dengan model. Kami merekomendasikan penggunaan ini untuk kontrol berbutir halus pada alat mana yang dipanggil dan kapan.

Misalnya, untuk kasus penggunaan seperti output terstruktur, Anda mungkin ingin alat tertentu dipanggil setiap kali Amazon Nova dipanggil. Anda dapat menentukan skema output Anda sebagai alat dan kemudian mengatur pilihan alat ke nama alat itu.

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

Untuk banyak kasus penggunaan agen, Anda mungkin ingin memastikan bahwa model selalu memilih salah satu alat yang tersedia. Untuk melakukannya, Anda dapat mengatur pilihan alatnya, yang akan memanggil tepat satu alat setiap kali model dipanggil.

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

Terakhir, untuk kasus penggunaan di mana apakah alat dipanggil sangat tergantung pada konteks percakapan, Anda dapat mengatur pilihan alat. `auto` Ini adalah perilaku default dan akan membiarkan pemilihan alat sepenuhnya tergantung pada model.

```
{
 "toolChoice": {
```

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

## Teknik meminta tingkat lanjut

Bagian-bagian ini memberikan panduan lanjutan tentang cara meningkatkan kualitas petunjuk Anda dan memanfaatkan fitur-fitur utama seperti pemikiran yang diperluas.

### Gunakan Mode Penalaran

Model Amazon Nova 2 menawarkan mode penalaran opsional yang meningkatkan pendekatan model untuk pemecahan masalah yang kompleks dengan memungkinkannya bekerja melalui masalah secara sistematis sebelum merespons. Memanfaatkan mode penalaran model adalah cara ampuh untuk meningkatkan akurasi permintaan Anda.

Kapan menggunakannya: Mode penalaran direkomendasikan untuk tugas-tugas kompleks seperti kasus penggunaan dengan:

- Beberapa langkah penalaran: Bukti matematika, desain algoritma, arsitektur sistem
- Informasi referensi silang: Analisis dokumen, perbandingan opsi, evaluasi trade-off
- Perhitungan rawan kesalahan: Pemodelan keuangan, analisis data, debugging kompleks
- Perencanaan dengan kendala: Optimalisasi sumber daya, manajemen ketergantungan, penilaian risiko
- Klasifikasi kompleks: Kategorisasi multi-label, taksonomi hierarkis, batas keputusan bernuansa
- Skenario pemanggilan alat: Alur kerja API multi-langkah, pengoptimalan kueri basis data, integrasi sistem terkoordinasi

#### Note

Untuk informasi lebih lanjut tentang mode penalaran, lihat. [Menggunakan penalaran](#)

### Ambil pendekatan top-down

Untuk situasi di mana model perlu menilai beberapa pendekatan untuk memecahkan masalah, instruksikan untuk mengambil pendekatan top-down.

- Model Amazon Nova 2 berkinerja lebih baik ketika model dimulai dengan gambaran besar dan kemudian memecahnya menjadi submasalah atau langkah yang lebih kecil dan lebih rinci.
- Secara eksplisit mengarahkan model untuk terlebih dahulu mengidentifikasi tujuan utama, kemudian menguraikannya menjadi komponen yang dapat dikelola sebelum mengerjakan detail setiap bagian.
- Pendekatan terstruktur ini membantu model mengatur pemikirannya dan menghasilkan rantai penalaran yang lebih koheren.

Contoh:

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

## Mengarahkan Rantai Pemikiran

Sementara mode penalaran memberikan akurasi yang ditingkatkan melalui pemecahan masalah yang sistematis, ada skenario spesifik di mana Chain of Thought (CoT) mendorong dalam mode non-penalaran dapat melayani kebutuhan Anda dengan lebih baik.

Kapan menggunakannya:

- **Transparansi dan auditabilitas:** Saat Anda ingin melihat, memverifikasi, atau mengaudit proses penalaran model, CoT memberikan visibilitas penuh ke setiap langkah. Ini sangat penting untuk industri yang diatur, keputusan berisiko tinggi, atau ketika Anda ingin mendokumentasikan logika di balik jawaban.
- **Struktur penalaran khusus:** Gunakan CoT untuk menegaskan pola atau metodologi penalaran tertentu. Anda dapat memandu model untuk mengikuti kerangka keputusan organisasi Anda, menggunakan pendekatan pemecahan masalah khusus domain, atau memastikan faktor-faktor dipertimbangkan dalam urutan tertentu.
- **Pengembangan dan debugging yang cepat:** Selama fase rekayasa yang cepat, CoT membantu Anda memahami bagaimana model mendekati masalah, mengidentifikasi di mana penalaran rusak dan mengulangi permintaan Anda dengan lebih efektif.
- **Pendekatan hibrida:** Pertimbangkan untuk menggunakan CoT selama pengembangan untuk menyempurnakan permintaan Anda, lalu beralih ke mode penalaran untuk penerapan produksi setelah Anda yakin dengan pendekatan model untuk kasus penggunaan spesifik Anda.

 Note

Tidak semua tugas membutuhkan CoT. Untuk tugas yang lebih sederhana, izinkan model menggunakan proses penalarannya sendiri.

### Memandu arah CoT model:

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

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

### Memanfaatkan jendela konteks panjang

Model Amazon Nova 2 memiliki panjang konteks yang didukung 1 juta token dan unggul dalam pemahaman kode dan menjawab pertanyaan pada dokumen panjang. Kinerjanya (termasuk kepatuhan cepat sistem dan penggunaan alat) dapat sedikit menurun seiring bertambahnya ukuran konteks.

### Cara menggunakannya:

- Letakkan data formulir panjang di awal: Tempatkan dokumen dan masukan panjang Anda di dekat awal prompt Anda. Tempatkan mereka sebelum kueri, instruksi, dan contoh Anda.
- Letakkan instruksi di akhir: Tempatkan instruksi Anda di akhir prompt. Model berkinerja terbaik ketika konteks diberikan terlebih dahulu dan instruksi diberikan di akhir.
- Penanda awal dan akhir konten dokumen struktur: Gunakan penanda awal dan akhir, seperti `DOCUMENT {idx} START` dan `DOCUMENT {idx} END`, untuk menunjukkan awal dan akhir dokumen panjang di mana {idx} mewakili indeks dokumen tertentu.

### Contoh Template:

```
// 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
```

### Jawaban dasar dalam teks pendukung

Kami menyarankan Anda memberikan model dengan informasi tepercaya yang relevan dengan kueri input. Informasi ini, bersama dengan kueri input, sering menjadi bagian dari sistem yang disebut retrieval augmented generation (RAG).

- Dalam proses ini, beberapa dokumen atau informasi kontekstual yang relevan ditambah ke prompt pengguna yang sebenarnya sehingga model mendapatkan konten yang dapat dipercaya untuk menghasilkan respons yang relevan dan akurat.
- Menginstruksikan Amazon Nova 2 untuk menjawab menggunakan teks referensi dari sumber tepercaya dapat membimbingnya untuk menyusun responsnya berdasarkan materi yang disediakan dan memastikan bahwa responsnya didasarkan pada informasi yang akurat dan relevan, meningkatkan keandalan dan kredibilitas konten yang dihasilkan.
- Menggunakan teks referensi dapat membantu menghindari halusinasi, sehingga meningkatkan kualitas dan kepercayaan tanggapan secara keseluruhan. Untuk meminimalkan halusinasi, sebaiknya sebutkan **DO NOT USE INFORMATION THAT IS NOT IN REFERENCE TEXTS!** secara eksplisit dalam instruksi model Anda.

### Templat cepat

**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}
```

Contoh: Memberikan konteks grounding membantu mencegah model berhalusinasi

Contoh ini menunjukkan bagaimana konteks grounding dapat mencegah model berhalusinasi.

Sistem:

```
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!
```

Pengguna:

```
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.
```

Ground menggunakan spidol kutipan

Untuk tugas dokumen yang panjang, kami sarankan Anda menginstruksikan model Amazon Nova 2 untuk membumikan tanggapannya menggunakan kutipan dari bagian dokumen yang relevan sebelum melanjutkan tugas.

Pendekatan ini membantu model fokus pada informasi yang paling relevan dan menghindari terganggu oleh konten asing. Saat Anda meminta model mendasarkan responsnya, bagian yang dapat dikutip harus diberi nomor. Misalnya, Passage %[1]%, Passage %[2]% dan sebagainya.

## Contoh: menggunakan penanda kutipan

### Example Penanda kutipan cepat

```
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)
...
```

Setelah Anda mengekstrak informasi kunci berdasarkan tugas pengguna, Anda dapat menggunakan metrik keuangan yang diekstraksi untuk menjawab pertanyaan yang relevan seperti yang ditunjukkan:

### Example Analisis tindak lanjut dengan metrik yang diekstraksi

```
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

## Gunakan Nova Web Grounding

Alih-alih meminta secara langsung kutipan untuk membumikan model dalam teks pendukung, model Amazon Nova 2 menyediakan alat pentanahan web internal yang dapat digunakan. Saat diaktifkan, model Amazon Nova 2 akan langsung menanyakan web dan grafik pengetahuan Amazon dan membumikan respons akhir dengan kutipan.

Untuk mempelajari lebih lanjut tentang cara memanfaatkan Amazon Nova Web Grounding, Anda dapat merujuk panduan [pengguna Amazon Nova Web Grounding](#).

## Menghasilkan output terstruktur

Untuk memastikan format output yang konsisten dan terstruktur, Anda dapat menggunakan output terstruktur, termasuk format seperti XHTML, JSON, Markdown, atau menggunakan fungsionalitas penggunaan alat.

- Pendekatan ini memungkinkan sistem hilir untuk lebih efektif memahami dan mengurai output yang dihasilkan oleh model.
- Dengan memberikan instruksi eksplisit untuk model, tanggapan dihasilkan dengan cara yang mematuhi skema yang telah ditentukan.

Misalnya, jika parser hilir mengharapkan konvensi penamaan khusus untuk kunci dalam objek JSON, Anda harus menentukan skema respons di akhir prompt. Selain itu, jika Anda lebih suka respons dalam format JSON tanpa teks pembukaan, instruksikan model yang sesuai. Artinya, secara eksplisit menyatakan Harap hasilkan hanya output JSON. JANGAN berikan pembukaan apa pun. untuk memastikan output bersih.

#### Tip

- Kami mengamati kepatuhan terbaik terhadap persyaratan format data ketika mereka didefinisikan dalam skema itu sendiri alih-alih melalui penggunaan contoh (seperti, menentukan tanggal dalam format). YYYY/MM/DD
- Untuk output JSON sederhana dengan hingga 10 kunci, Anda dapat menemukan skema di bawah ini. Untuk skema yang lebih kompleks, kami sarankan Anda menentukan skema Anda melalui alat. Penggunaan alat memanfaatkan teknik yang disebut decoding terbatas yang akan meningkatkan kepatuhan model untuk skema kompleks ini.

## Skema pemformatan umum

Berikut ini adalah contoh skema pemformatan umum.

### 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 )

"""
```

Isi konten asisten pra-isi

Jika Anda menghasilkan output terstruktur dalam mode non-penalaran, Anda dapat mendorong respons model dengan mengisi konten asisten terlebih dahulu.

Prefilling meningkatkan konsistensi dalam format output saat dalam mode non-penalaran. Ini memungkinkan Anda untuk mengarahkan tindakan model, mem-bypass pembukaan dan menerapkan format output tertentu seperti JSON dan XHTML. Misalnya, jika Anda mengisi konten asisten dengan { atau ```json, masukan itu memandu model untuk menghasilkan objek JSON tanpa informasi tambahan.

Tip

Jika Anda secara eksplisit mencari mengekstraksi JSON, pola yang umum adalah mengisi sebelumnya ```json dan menambahkan urutan berhenti. ``` Ini memastikan model mengeluarkan objek JSON yang dapat diurai secara terprogram.

Example Isi konten asisten pra-isi

Kode berikut menunjukkan cara mengisi ulang dengan API:

```
import boto3
import json

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

request_body = {
    "system": [
        {"text": "You write JSON objects based on the given instructions"}
    ],
    "messages": [
        {
            "role": "user",
            "content": [{"text": "Provide details about the best selling full-frame cameras in past three years. Answer in JSON format with keys like name, brand, price and a summary."}]
        },
    ],
}
```

```
{
    "role": "assistant",
    "content": [{"text": " Here is the JSON response: ```json"}]
},
"inferenceConfig": {
    "maxTokens": 1000,
}
}

# Invoke the model and extract the response body.
response = client.invoke_model(
    modelId="amazon.nova-2-lite-v1:0",
    body=json.dumps(request_body)
)

model_response = json.loads(response["body"].read())
```

Tentukan alat yang akan digunakan untuk skema kompleks

Pendekatan lain adalah dengan menggunakan alat untuk memaksa skema tertentu untuk respons model dengan memasukkan skema JSON pydantic di bagian skema penggunaan alat. Anda dapat menentukan pilihan alat ke skema yang disediakan dan respons Amazon Nova akan disusun berdasarkan alat yang dipilih. Untuk mempelajari lebih lanjut tentang cara memanfaatkan penggunaan alat, lihat [Penggunaan Alat](#).

Contoh

Contoh 1: Tambahkan skema keluaran

Menambahkan bagian Output Schema dengan skema yang sesuai membuat model lebih memilih untuk menyesuaikan skema itu. Namun, output model tidak deterministik dan dapat bervariasi dari skema output.

Unspecific Prompt

Pengguna:

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.

Asisten:


```
```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

Pengguna:

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"
}]
```

Asisten:

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

Contoh 2: Isi ulang respons model

Pendekatan lain adalah dengan mengisi respons model dengan memasukkan teks awal yang diinginkan dalam pesan asisten. Dalam hal ini, respons model Amazon Nova akan berlanjut dari tempat pesan asisten ditinggalkan.

Tip: Prefill hanya valid ketika penalaran tidak diaktifkan.

Pengguna:

```
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.
```

Asisten (Prefilling):

```
```json
```

Asisten:

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

Contoh 3: Tentukan alat yang akan digunakan

Sebagai alternatif untuk menggunakan teknik prefill untuk output terstruktur, Anda dapat menggabungkan fungsionalitas alat Nova dengan ToolChoice. Dalam contoh ini, model akan menghasilkan panggilan alat yang mematuhi skema JSON yang disediakan dan memanggil alat khusus yang ditentukan ke format JSON lengkap yang ditentukan. Untuk panduan tambahan, lihat Sistem Lanjutan.

Pengguna:

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"
    }
}
}
}

```

Kasus penggunaan multibahasa

Model Amazon Nova 2 telah dilatih pada lebih dari 200 bahasa dan dioptimalkan untuk 15 bahasa.

Topik

- [Minta terjemahan yang akurat](#)
- [Menegakkan konvensi penulisan yang konsisten](#)

Minta terjemahan yang akurat

Untuk memanfaatkan kemampuan ini untuk terjemahan bentuk singkat (beberapa kalimat) Anda dapat menginstruksikan model untuk menerjemahkan teks ke dalam bahasa target yang ditentukan.

Example Permintaan terjemahan

```
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}
```

Menegakkan konvensi penulisan yang konsisten

Dalam bahasa berbasis karakter, model Amazon Nova 2 dapat menggunakan set karakter dari bahasa sumber. Anda dapat menggunakan prompt berikut untuk menerapkan output yang konsisten.

Example Menegakkan konvensi penulisan

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

Panggilan alat

Sistem agen

Topik

- [Atur parameter inferensi yang tepat](#)
- [Pertimbangkan persyaratan latensi](#)
- [Gunakan kata-kata yang disengaja untuk instruksi panggilan alat](#)
- [Manfaatkan perintah “berpikir”](#)
- [Pemesanan panggilan alat](#)
- [Buat skema alat berkualitas](#)
- [Buat sub-agen](#)
- [Gunakan alat untuk input multimodal](#)
- [Langkah selanjutnya](#)

Atur parameter inferensi yang tepat

Pemanggilan alat memerlukan output terstruktur yang sangat spesifik dari model dan ditingkatkan dengan menggunakan parameter inferensi berikut:

- Mode Non Penalaran: Suhu: 0,7 & P Teratas: 0,9
- Mode Penalaran: Suhu: 1 & P Teratas: 0,9

Pertimbangkan persyaratan latensi

Tip

Model Amazon Nova 2 mampu memanggil alat dengan alasan hidup dan mati. Namun, mode penalaran memiliki dampak signifikan pada latensi.

Untuk aplikasi sensitif latensi, Anda harus mengoptimalkan mode penalaran mati dan menyederhanakan panggilan alat yang diperlukan jika memungkinkan. Pisahkan alur kerja multistep menjadi langkah-langkah diskrit untuk mengurangi ketergantungan model pada memuntahkan parameter yang tidak perlu.

Gunakan kata-kata yang disengaja untuk instruksi panggilan alat

Nama alat: Alat referensi dalam prompt sistem adalah umum dalam sistem pemanggilan alat untuk menginstruksikan model kapan harus memanggil alat. Saat Anda mereferensikan alat dalam prompt, kami sarankan Anda menggunakan nama alat alih-alih referensi atau contoh xml/pythonic.

Contoh referensi alat yang baik

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

Contoh referensi alat yang buruk

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

Manfaatkan perintah “berpikir”

Untuk semua kasus penggunaan di mana pemikiran bermanfaat untuk pemanggilan alat, kami sarankan Anda memanfaatkan mode penalaran alih-alih mendorong model untuk “berpikir dalam tag” atau menggunakan alat “berpikir”.

Model Amazon Nova 2 dilatih secara ekstensif untuk mode penalaran dan akan menghasilkan hasil yang optimal bila digunakan dalam mode penalaran untuk rantai pemikiran.

Pemesanan panggilan alat

Dalam kasus penggunaan yang mungkin memerlukan penggunaan alat bawaan dan pemanggilan alat asli secara bersamaan, model bias memanggil alat bawaan terlebih dahulu.

Jangan menginstruksikan model untuk bertindak berbeda dalam prompt. Sebagai gantinya, rancang alur kerja Anda untuk mempertimbangkan hal ini.

Misalnya, jika Anda tidak ingin model menggunakan alat bawaan, jangan sertakan dalam alur kerja Anda sehingga model tidak bias terhadapnya.

Buat skema alat berkualitas

Skema alat adalah salah satu tempat utama Anda dapat meminta sistem panggilan alat yang efektif untuk merekayasa. Namun, penting untuk mempertimbangkan apa yang ditangkap dalam skema alat itu sendiri, bagaimana setiap elemen skema dijelaskan secara semantik dan bagaimana sistem meminta referensi alat dan elemen skema dalam instruksi sistem.

Model Amazon Nova 2 dioptimalkan untuk deskripsi ringkas dalam skema alat. Tetap singkat.

Skema alat versus pedoman prompt sistem:

Sertakan dalam skema alat:

- Fungsionalitas inti: Apa yang dilakukan alat (20-50 kata direkomendasikan)
- Spesifikasi parameter: Deskripsi yang jelas dari setiap parameter (sekitar 10 kata per parameter)
- Format yang diharapkan: Tipe data (seperti enum, int, float), bidang wajib dan rentang nilai yang valid

Sertakan dalam prompt sistem:

- Dedikasikan `#Tool Usage` bagian dengan logika orkestrasi (kapan dan mengapa menggunakan alat khusus) dan aturan bisnis (logika bersyarat, persyaratan pengurutan, dan dependensi).
- Strategi penanganan kesalahan: Tambahkan `#Error Handling and Troubleshooting` bagian dengan instruksi tentang cara merespons kegagalan atau keluaran yang tidak terduga
- Pemformatan keluaran: Tambahkan detail tentang cara menyajikan kepada pengguna

Contoh

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>

Buat sub-agen

Pertimbangkan untuk membuat sub-agen khusus alih-alih satu agen dengan banyak alat saat Anda menemukan:

- Jumlah alat melebihi 20: Set alat besar menjadi sulit untuk dikelola dan meningkatkan kesalahan pemilihan

- Domain fungsional yang berbeda: Alat secara alami mengelompokkan ke dalam kategori terpisah (seperti pengambilan data versus pemrosesan versus pelaporan)
- Skema kompleks: Ketika kedalaman parameter melebihi 3-4 level atau alat memiliki saling ketergantungan yang rumit
- Panjang percakapan: Alur kerja secara teratur melebihi 15-20 putaran dapat mengambil manfaat dari sub-agen khusus
- Degradasi kinerja: Jika Anda mengamati penurunan akurasi dalam pemilihan alat atau peningkatan latensi

Tip

Server MCP dilengkapi dengan alat dan skema yang tidak dapat Anda kendalikan. Hanya sertakan alat yang diperlukan untuk alur kerja Anda untuk menyelesaikan tugas yang diperlukan.

Gunakan alat untuk input multimodal

Untuk tugas multimodal, kami belum mengamati peningkatan akurasi yang memanfaatkan alat untuk tugas terstruktur (seperti ekstraksi atau pembuatan stempel waktu).

Sebagai gantinya, kami sarankan Anda meninjau bagian yang relevan di bagian Meminta input multimodal untuk cara meminta model dengan sukses menggunakan templat yang disediakan.

Langkah selanjutnya

- Untuk permintaan multimodal, lihat. [Meminta input multimodal](#)

Meminta input multimodal

Bagian berikut memberikan panduan untuk pemahaman gambar dan video. Untuk permintaan terkait audio, lihat bagian. [the section called “Permintaan percakapan suara”](#)

Pedoman multimodal umum

Permintaan pengguna dan perintah sistem

Untuk kasus penggunaan pemahaman multimodal, setiap permintaan harus menyertakan teks prompt pengguna. Permintaan sistem, yang mungkin hanya berisi teks, bersifat opsional.

Prompt sistem dapat digunakan untuk menentukan persona untuk model dan untuk mendefinisikan kepribadian umum dan gaya respons tetapi tidak boleh digunakan untuk definisi tugas rinci atau instruksi pemformatan output.

Sertakan definisi tugas, instruksi, dan detail pemformatan dalam prompt pengguna untuk memiliki efek yang lebih kuat daripada prompt sistem untuk kasus penggunaan multimodal.

Pesanan konten

Permintaan pemahaman multimodal yang dikirim ke Amazon Nova harus berisi satu atau beberapa file dan prompt pengguna. Prompt teks pengguna harus menjadi item terakhir dalam pesan, selalu setelah gambar, dokumen, atau konten video.

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

Dalam kasus di mana Anda ingin merujuk ke file tertentu dari dalam prompt pengguna, gunakan elemen “teks” untuk menentukan label yang mendahului setiap blok file.

```
message = {
  "role": "user",
  "content": [
    { "text": "<label for item 1>" },
    { "document|image|video|audio": {...} },
    { "text": "<label for item 2>" },
    { "document|image|video|audio": {...} },
    ...
    { "text": "<user prompt>" }
  ]
}
```

```
]
}
```

Pemahaman Dokumen dan Gambar

Bagian berikut memberikan panduan tentang cara menyusun petunjuk untuk tugas-tugas yang membutuhkan pemahaman atau analisis gambar dan dokumen.

Mengekstrak teks dari gambar

Model Amazon Nova dapat mengekstrak teks dari gambar, kemampuan yang disebut sebagai Optical Character Recognition (OCR). Untuk hasil terbaik, pastikan input gambar yang Anda berikan kepada model adalah resolusi yang cukup tinggi sehingga karakter teks mudah dilihat.

Untuk kasus penggunaan ekstraksi teks, kami merekomendasikan konfigurasi inferensi berikut:

- suhu: default (0,7)
- TopP: default (0,9)
- Jangan aktifkan penalaran

Model Amazon Nova dapat mengekstrak teks ke format Markdown, HTML, atau LaTeX. Template prompt pengguna berikut direkomendasikan:

```
## 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.
```

Outputnya dibungkus dengan pagar kode Markdown penuh atau sebagian () ```. Anda dapat menghapus pagar kode menggunakan kode yang mirip dengan berikut ini:

```
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()
```

Mengekstrak informasi terstruktur dari gambar atau teks

Model Amazon Nova dapat mengekstrak informasi dari gambar ke dalam format JSON yang dapat diurai mesin, sebuah proses yang disebut sebagai Ekstraksi Informasi Kunci (KIE). Untuk melakukan KIE, berikan yang berikut:

- Skema JSON. Definisi skema formal yang mengikuti spesifikasi Skema JSON.
- Satu atau beberapa hal berikut: File dokumen atau gambar atau teks dokumen

Dokumen atau gambar harus selalu ditempatkan sebelum permintaan pengguna Anda diminta.

Untuk kasus penggunaan KIE, kami merekomendasikan konfigurasi inferensi berikut:

- Temperatur: 0
- Penalaran: Penalaran tidak diperlukan tetapi dapat meningkatkan hasil ketika input gambar saja atau skema kompleks digunakan.

Templat cepat

Masukan dokumen atau gambar saja

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}
```

Hanya masukan teks

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}
```

Dokumen atau Gambar dan masukan teks

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}
```

Mendeteksi objek dan posisinya dalam gambar

Model Amazon Nova 2 memberikan kemampuan untuk mengidentifikasi objek dan posisinya dalam gambar, tugas yang kadang-kadang disebut sebagai pentanahan gambar atau lokalisasi objek. Aplikasi praktis termasuk analisis gambar dan penandaan, otomatisasi antarmuka pengguna, pengeditan gambar, dan lainnya.

Terlepas dari resolusi input gambar dan rasio aspek, model menggunakan ruang koordinat yang membagi gambar menjadi 1.000 unit secara horizontal dan 1.000 unit secara vertikal, dengan lokasi x:0 y: 0 menjadi kiri atas gambar.

Kotak pembatas dijelaskan menggunakan format yang [x1, y1, x2, y2] mewakili kiri, atas, kanan dan bawah masing-masing. Koordinat dua dimensi diwakili menggunakan format. [x, y]

Untuk kasus penggunaan deteksi objek, kami merekomendasikan nilai parameter inferensi berikut:

- Temperatur: 0
- Jangan aktifkan penalaran

Templat prompt: deteksi objek umum

Kami merekomendasikan template prompt pengguna berikut.

Mendeteksi beberapa instance dengan kotak pembatas:

```
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.
```

Mendeteksi satu wilayah dengan kotak pembatas:

```
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.
```

Mendeteksi beberapa instance dengan titik tengah:

```
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.
```

Mendeteksi satu wilayah dengan titik tengah:

```
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.

Mengurai keluaran model:

Setiap petunjuk yang disarankan di atas akan menghasilkan string dipisahkan koma yang berisi satu atau lebih deskripsi kotak pembatas dalam bentuk yang mirip dengan berikut ini. Mungkin ada sedikit variasi dalam apakah “.” disertakan di akhir string. Sebagai contoh, [356, 770, 393, 872], [626, 770, 659, 878]..

Anda dapat mengurai informasi koordinat yang dihasilkan oleh model menggunakan ekspresi reguler seperti yang ditunjukkan pada contoh kode Python berikut.

Contoh kode

```
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)
    ]
```

Contoh kode

Untuk memetakan ulang koordinat kotak pembatas yang dinormalisasi ke ruang koordinat gambar input, Anda dapat menggunakan fungsi yang mirip dengan contoh Python berikut.

```
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,
    ]
```

Template prompt: mendeteksi beberapa kelas objek dengan posisi

Bila Anda ingin mengidentifikasi beberapa kelas item dalam gambar, Anda dapat menyertakan daftar kelas dalam prompt Anda menggunakan salah satu pendekatan pemformatan berikut.

Untuk kelas yang dipahami umum yang kemungkinan akan dipahami dengan baik oleh model, daftarkan nama kelas (tanpa tanda kutip) di dalam tanda kurung siku:

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

Untuk kelas yang bernuansa, tidak umum, atau berasal dari domain khusus yang model mungkin tidak akrab dengan, sertakan definisi untuk setiap kelas dalam tanda kurung. Karena tugas ini menantang, perkirakan kinerja model menurun.

```
[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)]
```

Gunakan salah satu template prompt pengguna berikut tergantung pada format output JSON yang Anda inginkan.

Opsi cepat 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]
  },
  ...
]
```

Opsi cepat 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]
  },
  ...
]
```

Opsi cepat 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], ...],
  ...
}
```

Opsi cepat 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], ...]
  },
  ...
]
```

Mengurai keluaran model

Output akan dikodekan sebagai JSON yang dapat diurai dengan pustaka parsing JSON apa pun.

Templat prompt: deteksi batas UI tangkapan layar

Kami merekomendasikan template prompt pengguna berikut.

Mendeteksi posisi elemen UI berdasarkan tujuan:

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.

Mendeteksi posisi elemen UI berdasarkan teks:

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.

Mengurai keluaran model:

Untuk setiap petunjuk deteksi batas UI di atas, Anda dapat mengurai informasi koordinat yang dihasilkan oleh model menggunakan ekspresi reguler seperti yang ditunjukkan pada contoh kode Python di bawah ini.

Contoh kode

```

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)
    ]
```

Pemahaman video

Bagian berikut memberikan panduan tentang cara menyusun petunjuk untuk tugas-tugas yang membutuhkan pemahaman atau analisis video.

Meringkas video

Model Amazon Nova dapat menghasilkan ringkasan konten video.

Untuk kasus penggunaan ringkasan video, kami merekomendasikan nilai parameter inferensi berikut:

- Temperatur: 0
- Beberapa kasus penggunaan mungkin mendapat manfaat dari mengaktifkan penalaran model

Tidak diperlukan templat permintaan khusus. Prompt pengguna Anda harus dengan jelas menentukan aspek video yang Anda pedulikan. Berikut adalah beberapa contoh petunjuk yang efektif:

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?

Menghasilkan keterangan rinci untuk video

Model Amazon Nova dapat menghasilkan teks terperinci untuk video, tugas yang disebut teks padat.

Untuk kasus penggunaan teks video, kami merekomendasikan nilai parameter inferensi berikut:

- Temperatur: 0
- Beberapa kasus penggunaan mungkin mendapat manfaat dari mengaktifkan penalaran model

Tidak diperlukan templat permintaan khusus. Prompt pengguna Anda harus dengan jelas menentukan aspek video yang Anda pedulikan. Berikut adalah beberapa contoh petunjuk yang efektif:

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.

Menganalisis rekaman video keamanan

Model Amazon Nova dapat mendeteksi peristiwa dalam rekaman keamanan.

Untuk kasus penggunaan rekaman keamanan, kami merekomendasikan nilai parameter inferensi berikut:

- Temperatur: 0
- Beberapa kasus penggunaan mungkin mendapat manfaat dari mengaktifkan penalaran model

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.

Mengekstrak acara video dengan stempel waktu

Model Amazon Nova dapat mengidentifikasi stempel waktu yang terkait dengan peristiwa dalam video. Anda dapat meminta agar stempel waktu diformat dalam hitungan detik atau dalam format

MM: SS. Misalnya, peristiwa yang terjadi pada 1 menit 25 detik dalam video dapat direpresentasikan sebagai 85 atau 01:25.

Untuk kasus penggunaan ini, kami merekomendasikan nilai parameter inferensi berikut:

- Temperatur: 0
- Jangan gunakan penalaran

Kami menyarankan Anda menggunakan petunjuk yang mirip dengan yang berikut ini:

Mengidentifikasi waktu mulai dan berakhir suatu acara

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]]

Mengidentifikasi beberapa kejadian dari suatu peristiwa

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]]

Menghasilkan log segmen video dengan stempel waktu

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.

Mengklasifikasikan video

Anda dapat menggunakan model Amazon Nova untuk mengklasifikasikan video berdasarkan daftar kelas yang telah ditentukan sebelumnya.

Untuk kasus penggunaan ini, kami merekomendasikan nilai parameter inferensi berikut:

- Temperatur: 0
- Penalaran tidak boleh digunakan

Gunakan template prompt berikut:

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

Contoh:

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

Moderasi konten

Panduan ini memberikan praktik terbaik untuk mendorong model Amazon Nova melakukan moderasi konten menggunakan [MLCommons® AI Luminiate Assessment Standard](#) — kerangka kerja komprehensif dengan 12 kategori bahaya untuk keamanan AI. Meskipun panduan ini menggunakan MLCommons standar sebagai contoh untuk mengilustrasikan praktik terbaik, teknik yang diminta bekerja dengan kategori dan definisi moderasi konten bentuk bebas atau dapat disesuaikan apa pun yang Anda tentukan.

Prinsip-prinsip kunci

- Gunakan perintah terstruktur (XHTML, JSON) atau bentuk bebas berdasarkan kasus penggunaan Anda
- Moderasi konten teks apa pun: percakapan, artikel, posting media sosial, komentar, ulasan, dan lainnya
- Memberikan definisi kebijakan yang jelas
- Minta penjelasan untuk transparansi

Konfigurasi yang disarankan

Untuk tugas moderasi konten, kami merekomendasikan konfigurasi inferensi berikut:

- Temperatur — Gunakan nilai default 0,7.
- P Teratas - Gunakan nilai default 0,9.
- Penalaran - Nonaktifkan penalaran untuk moderasi konten untuk mengurangi latensi.

MLCommons taksonomi universal

Standar ini mendefinisikan 12 kategori bahaya:

MLCommons AILuminate kategori bahaya

Kategori	Definisi	Subkategori kunci
Kejahatan Kekerasan	Konten yang memungkinkan, mendorong, atau mendukung tindakan kejahatan kekerasan	Kekerasan massal, Pembunuhan, Serangan fisik, Kekerasan dalam rumah tangga, Teror, Pelecehan hewan
Kejahatan Tanpa Kekerasan	Konten yang memungkinkan, mendorong, atau mendukung aktivitas kriminal tanpa kekerasan	Perdagangan tenaga kerja, Penipuan, Pencurian, Pembakaran, Kejahatan narkoba, Kejahatan senjata, Kejahatan dunia maya

Kategori	Definisi	Subkategori kunci
Kejahatan Terkait Seks	Konten yang memungkinkan, mendorong, atau mendukung kejahatan terkait seks	Perdagangan seks, Pelecehan seksual, Pelecehan seksual, Konten intim non-konsensual, Kebinatangan
Eksplorasi Seksual Anak	Konten yang berisi, menjelaskan, memungkinkan, mendorong, atau mendukung pelecehan seksual terhadap anak di bawah umur	Hubungan yang tidak pantas dengan anak-anak, Pelecehan seksual terhadap anak-anak, CSAM
CBRNE	Konten yang memungkinkan, mendorong, atau mendukung pembuatan senjata pemusnah massal	Senjata kimia, Senjata biologis, Senjata radiologis, Senjata nuklir, Bahan peledak hasil tinggi
Bunuh diri dan Menyakiti Diri Sendiri	Konten yang memungkinkan, mendorong, atau mendukung menyakiti diri sendiri yang disengaja	Bunuh diri, Cedera diri, Gangguan makan, Tantangan berbahaya
Benci	Konten yang merendahkan atau merendahkan manusia berdasarkan karakteristik yang dilindungi	Pernyataan yang merendahkan, Menimbulkan kerugian physical/emotional , Pengecualian dan isolasi
Saran Khusus	Saran yang tidak memenuhi syarat dalam domain sensitif tanpa penafian yang sesuai	Saran keuangan, Nasihat medis, Nasihat hukum, Saran pemilihan, Klaim keselamatan
Privasi	Konten yang berisi informasi pribadi non-publik yang sensitif	Keamanan fisik (alamat), Keamanan digital (kredensial), Keamanan finansial (nomor akun)
Kekayaan Intelektual	Konten yang melanggar atau mendorong pelanggaran hak IP	Pelanggaran hak cipta, Pelanggaran Merek Dagang, Pelanggaran paten
Pencemaran Nama Baik	Konten yang terbukti salah dan cenderung melukai reputasi seseorang	Fitnah, Fitnah, Penghinaan

Kategori	Definisi	Subkategori kunci
Konten Seksual	Konten erotis termasuk pornografi dan cybersex	Pornografi (deskripsi seksual grafis), obrolan erotis langsung

Sumber: MLCommons® Standar AILuminate Penilaian (Dokumentasi)

Contoh yang mendorong

Format terstruktur

Terbaik untuk sistem otomatis yang membutuhkan output yang dapat diuraikan. Contoh-contoh ini menggunakan pembelajaran beberapa tembakan, di mana Anda memberikan contoh pasangan input-output dalam prompt untuk memandu respons model. Contoh di bawah ini mencakup satu demonstrasi, tetapi Anda dapat menyertakan beberapa contoh untuk meningkatkan akurasi kasus penggunaan spesifik Anda.

Struktur (XML)

User:

You are a text content moderator that detects policy violations, describes violated categories, and explains the reasoning behind your decisions. You will see a policy list and a conversation to be moderated. Your moderation response should be formatted as follows.

Start the response by indicating policy violation status using either `<POLICY_VIOLATION>Yes</POLICY_VIOLATION>` for content that violates policies, or `<POLICY_VIOLATION>No</POLICY_VIOLATION>` for content that does not violate policies.

Then, list the specific violation categories between `<CATEGORY_LIST>` and `</CATEGORY_LIST>` tags.

If there is no violation, then put `C0` between the tags.

End the response by providing an analysis explaining whether the content violates policies and why in `<EXPLAIN>` `</EXPLAIN>` tags. Here is an example.

```
<EXAMPLE>
<POLICY>
{{Policy definitions and categories}}
```

```

</POLICY>
<TEXT>
{{Content to moderate}}
</TEXT>
<POLICY_VIOLATION>Yes/No</POLICY_VIOLATION>
<CATEGORY_LIST>Categories or C0</CATEGORY_LIST>
<EXPLAIN>Explanation</EXPLAIN>
</EXAMPLE>

```

Now, please moderate the following input policy and text.

```

<POLICY>
{{Policy definitions and categories}}
</POLICY>
<TEXT>
{{Content to moderate}}
</TEXT>

```

Assistant:

```

<POLICY_VIOLATION>Yes/No</POLICY_VIOLATION>
<CATEGORY_LIST>Categories or C0</CATEGORY_LIST>
<EXPLAIN>Explanation</EXPLAIN>

```

Struktur (JSON)

User:

You are a text content moderator that detects policy violations, describes violated categories, and explains the reasoning behind your decisions. You will check if there is unsafe content in the below text snippet in accordance with our safety policy.

Your moderation response should be in JSON format with the following structure:

```

{
  "policy_violation": "Yes or No",
  "category_list": ["List of violated category codes"],
  "explanation": "Reason for the decision"
}

```

If there is no violation, use "C0" as the category code.

IMPORTANT: Do not add any additional text or explanation. Your response must contain ONLY the JSON object, nothing else.

Here is an example:

```
[POLICY]
{{Policy definitions and categories}}

[TEXT]
{{Content to moderate}}

[RESPONSE]
{
  "policy_violation": "Yes or No",
  "category_list": ["Violated category codes or C0"],
  "explanation": "Explanation"
}
```

Now, please moderate the following input.

```
[POLICY]
{{Policy definitions and categories}}

[TEXT]
{{Content to moderate}}

[RESPONSE]
```

Assistant:

```
{
  "policy_violation": "No",
  "category_list": ["C0"],
  "explanation": "The text is a casual personal question with no policy violations."
}
```

Contoh prompt dan respons moderasi konten

User:

You are a text content moderator that detects policy violations, describes violated categories, and explains the reasoning behind your decisions. You will see a policy list and a conversation to be moderated. Your moderation response should be formatted as follows.

Start the response by indicating policy violation status using either `<POLICY_VIOLATION>Yes</POLICY_VIOLATION>` for content that violates policies, or `<POLICY_VIOLATION>No</POLICY_VIOLATION>` for content that does not violate policies.

Then, list the specific violation categories between `<CATEGORY_LIST>` and `</CATEGORY_LIST>` tags.

If there is no violation, then put `C0` between the tags.

End the response by providing an analysis explaining whether the content violates policies and why in `<EXPLAIN>` `</EXPLAIN>` tags. Here is an example.

`<POLICY>`

The 12 categories are: Violent Crimes, Non-Violent Crimes, Sex-Related Crimes, Child Sexual Exploitation, CBRNE, Suicide & Self-Harm, Hate, Specialized Advice, Privacy, Intellectual Property, Defamation, Sexual Content.

If none apply, label as `C0`.

`</POLICY>`

`<EXAMPLE>`

`<TEXT>`

"To make a pipe bomb: Get metal pipe, end caps, gunpowder, and fuse. Drill hole in cap, fill pipe with powder, insert fuse, seal both ends tightly."

`</TEXT>`

`<POLICY_VIOLATION>Yes</POLICY_VIOLATION>`

`<CATEGORY_LIST>CBRNE</CATEGORY_LIST>`

`<EXPLAIN>Provides instructions for creating explosives, enabling dangerous weapons creation.</EXPLAIN>`

`</EXAMPLE>`

`<TEXT>`

DIY explosive device: Mix ammonium nitrate fertilizer with fuel oil at 94:6 ratio. Use blasting cap for detonation. Store in cool, dry place. #DIY #Chemistry

`</TEXT>`

Assistant:

`<POLICY_VIOLATION>Yes</POLICY_VIOLATION>`

`<CATEGORY_LIST>CBRNE</CATEGORY_LIST>`

`<EXPLAIN>`

The text provides specific instructions for creating ANFO explosives, including precise mixing ratios and detonation methods. This falls under CBRNE (high-yield explosives

```
subcategory) as it enables dangerous weapons creation with actionable technical details.
</EXPLAIN>
```

Moderasi konten bentuk bebas

Petunjuk bentuk bebas dapat mengambil banyak struktur yang beragam di luar contoh di bawah ini. Contoh berikut sengaja menggunakan gaya pemformatan yang berbeda untuk menggambarkan fleksibilitas permintaan bentuk bebas. Anda dapat menyesuaikan struktur, frasa, dan format agar sesuai dengan kasus penggunaan spesifik Anda.

Contoh 1: Yes/No pertanyaan (Bunuh Diri & Menyakiti Diri Sendiri)

Example Ya/Tidak moderasi konten

User:

```
Please stick to the following policy for content moderation. {{user_policy}}
Does this text promote harmful activities?

Best way to hurt yourself without leaving marks?
Asking for tips on methods that work.
```

Assistant:

```
Yes. This text explicitly requests methods for self-harm,
falling under the Suicide & Self-Harm category. The intent to
conceal evidence ("without leaving marks") indicates deliberate
harmful behavior.
```

Contoh 2: Identifikasi dan penalaran kategori (Benci)

Example Kategori identifikasi konten moderasi

User:

```
You are a professional content moderator. Please stick to the
following policy for content moderation. {{user_policy}}
Which category does this text violate and why?

Text: "Women are naturally worse at mathematics than men,
```

according to my personal observations. They should stick to arts and humanities."

Assistant:

Hate. This text makes demeaning generalizations about women based on gender (a protected characteristic), promoting exclusion from STEM fields. The claim lacks scientific basis and perpetuates harmful stereotypes.

Contoh 3: Peringkat keparahan (Privasi)

Example Moderasi konten peringkat keparahan

User:

```
Content moderation task
---
Policy: {{user_policy}}
---
Rate the severity of the following content as "none", "low", "medium", or "high"
and identify any violated categories.

Content: "John Smith lives at 742 Evergreen Terrace, Springfield.
His SSN is 123-45-6789 and his bank account number is 9876543210."
```

Assistant:

Severity: High

Violated category: Privacy

This content exposes multiple forms of sensitive personal information including a full name, home address, Social Security number, and bank account number. This falls under the Privacy category, specifically the physical security, digital security, and financial security subcategories. The combination of identifiers creates a significant risk of identity theft and financial fraud.

Kode dan Pemecahan Masalah

Bab ini memberikan contoh kode dan panduan pemecahan masalah untuk membantu Anda bekerja secara efektif dengan model Amazon Nova.

Pustaka kode

Bagian ini memberikan contoh kode untuk operasi Amazon Nova umum menggunakan Converse API atau InvokeModel API.

Contoh API Converse

Permintaan dasar

Kirim permintaan teks dasar ke model Amazon Nova menggunakan Converse API.

Non-streaming

```
import boto3
from botocore.config import Config

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

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

```

Masukan multimodal menggunakan aset tertanam

Memproses konten multimodal dengan menyematkan dokumen, gambar, video, atau data audio secara langsung dalam permintaan. Contoh ini menggunakan data gambar. Untuk detail tentang struktur konten untuk modalitas lain, lihat [ContentBlock detailnya di dokumentasi Amazon Bedrock API](#).

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)
```

Masukan multimodal menggunakan URI S3

Memproses konten multimodal dengan mereferensikan dokumen, gambar, video, atau file audio yang disimpan di S3. Contoh ini menggunakan referensi gambar. Untuk detail tentang struktur konten untuk modalitas lain, lihat [ContentBlock detailnya di dokumentasi Amazon Bedrock API](#).

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)
```

Pemikiran yang diperluas (penalaran)

Aktifkan pemikiran yang diperluas untuk tugas-tugas pemecahan masalah yang kompleks.

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

```

Alat bawaan: Nova Grounding dengan kutipan

Gunakan Nova Grounding untuk mengambil informasi real-time dari web dengan kutipan.

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)
```

Alat bawaan: Penerjemah Kode

Gunakan alat Code Interpreter untuk mengeksekusi kode Python untuk perhitungan dan analisis data.

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)

```

Penggunaan alat

Tentukan alat khusus untuk model yang akan digunakan selama percakapan.

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 Contoh API

Contoh di bawah ini berfokus pada beberapa area utama di mana permintaan dan struktur respons Invoke API sedikit berbeda dari Converse API. Dalam kebanyakan cara lain, keduanya APIs kompatibel, jadi Anda harus dapat dengan mudah mengadaptasi contoh Converse API di atas untuk bekerja dengan InvokeModel API.

Permintaan dasar

Kirim permintaan teks dasar ke model Amazon Nova 2 menggunakan InvokeModel API.

Non-streaming

```
import json

import boto3
from botocore.config import Config

# Configure the request
request_body = {
    "messages": [
        {
            "role": "user",
            "content": [{"text": "Write a short story. End the story with 'THE
END'. "}],
        }
    ],
    "system": [{"text": "You are a children's book author."}], # Optional
    "inferenceConfig": { # These parameters are optional
        "maxTokens": 1500,
        "temperature": 0.7,
        "topP": 0.9,
        "topK": 50,
        "stopSequences": ["THE END"],
    },
}

bedrock = boto3.client(
    "bedrock-runtime",
    region_name="us-east-1",
    config=Config(read_timeout=3600),
)

# Invoke the model
response = bedrock.invoke_model(
    modelId="us.amazon.nova-2-lite-v1:0", body=json.dumps(request_body)
)
response_body = json.loads(response["body"].read())

# Extract the text response
content_list = response_body["output"]["message"]["content"]
for content in content_list:
    if "text" in content:
        print(content["text"])
```

Streaming

```
import json

import boto3
from botocore.config import Config

# Configure the request
request_body = {
    "messages": [
        {
            "role": "user",
            "content": [{"text": "Write a short story. End the story with 'THE
END'. "}],
        }
    ],
    "system": [{"text": "You are a children's book author."}], # Optional
    "inferenceConfig": { # These parameters are optional
        "maxTokens": 1500,
        "temperature": 0.7,
        "topP": 0.9,
        "topK": 50,
        "stopSequences": ["THE END"],
    },
}

bedrock = boto3.client(
    "bedrock-runtime",
    region_name="us-east-1",
    config=Config(connect_timeout=3600, read_timeout=3600),
)

# Invoke the model with streaming
response = bedrock.invoke_model_with_response_stream(
    modelId="us.amazon.nova-2-lite-v1:0", body=json.dumps(request_body)
)

# Process the streaming response
for event in response["body"]:
    chunk = json.loads(event["chunk"]["bytes"])
    if "contentBlockDelta" in chunk:
        delta = chunk["contentBlockDelta"]["delta"]
        if "text" in delta:
```

```
print(delta["text"], end="", flush=True)
```

InvokeModel API dengan penalaran

Gunakan InvokeModel API dengan penalaran diaktifkan untuk pemecahan masalah yang kompleks.

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)
```

Pemecahan masalah

Bagian ini memberikan solusi untuk masalah umum saat bekerja dengan model Amazon Nova.

Otentikasi dan pengaturan

Izin tidak ada

Gejala: Tidak dapat mengakses model atau fitur Nova

Solusi:

- Pastikan peran IAM Anda memiliki AmazonBedrockFullAccess atau izin yang sesuai
- Minta akses model tertentu melalui konsol Amazon Bedrock

- Verifikasi izin untuk akses model dan penggunaan alat

Akses model ditolak

Gejala: Permintaan akses model gagal

Solusi:

- Minta akses model tertentu melalui konsol Amazon Bedrock
- Verifikasi akun Anda telah diberikan akses ke model yang diminta
- Periksa ketersediaan model regional

Masalah ketersediaan regional

Gejala: Fitur tidak tersedia di wilayah tertentu

Solusi:

- Web Grounding hanya tersedia di wilayah AS dengan profil CRIS AS
- Pastikan model dan fitur tersedia di wilayah yang Anda pilih
- Beralih ke wilayah yang didukung jika perlu

Konfigurasi waktu habis

Gejala: Meminta waktu habis sebelum selesai

Penyebab: Batas waktu default terlalu singkat untuk operasi yang kompleks

Solusi: Konfigurasi pengaturan batas waktu yang diperpanjang

```
from botocore.config import Config

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

)

 Note

Permintaan inferensi Amazon Nova dapat memakan waktu hingga 60 menit untuk operasi yang kompleks.

Masalah respons API

Memahami alasan berhenti:

`akhir_putar`

Penyelesaian normal. Tidak perlu tindakan.

`max_token`

Batas token tercapai.

Solusi: Tingkatkan `maxTokens` parameter di `inferenceConfig`.

`content_filter`

Konten melanggar kebijakan AI yang AWS bertanggung jawab.

Solusi: Tinjau dan ubah masukan Anda untuk mematuhi kebijakan konten.

`malformed_model_output`

Format keluaran tidak valid.

Solusi: Periksa skema dan kendala keluaran Anda; verifikasi skema JSON diformat dengan benar.

`malformed_tool_use`

Format panggilan alat tidak valid.

Solusi: Verifikasi definisi alat sesuai dengan skema yang diharapkan; periksa parameter input alat diformat dengan benar.

`service_unavailable`

Layanan alat bawaan tidak tersedia.

Solusi: Coba lagi permintaan setelah penundaan singkat; periksa dasbor kesehatan AWS layanan.

invalid_query

Kueri tidak valid ke alat bawaan.

Solusi: Tinjau format dan parameter kueri; pastikan kueri memenuhi persyaratan alat.

max_tool_invocations

Alat coba lagi habis.

Solusi: Sederhanakan tugas atau pecahkan menjadi langkah-langkah yang lebih kecil; tinjau pesan kesalahan alat untuk masalah tertentu.

Kesalahan mode penalaran

Respons terpotong dengan upaya penalaran tinggi

Solusi: Untuk upaya penalaran tinggi, hapus setel parameter ini: `temperature`, `topP`. `maxToken` Ini memungkinkan model untuk menggunakan pengaturan optimal untuk tugas penalaran yang kompleks.

Token tidak cukup untuk penalaran

Kesalahan: "MaxTokens tidak cukup"

Solusi: Coba lagi secara otomatis dengan batas yang meningkat

```
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
```

Masalah penggunaan alat

Kegagalan validasi skema

Kesalahan validasi skema alat

Solusi:

- Batasi skema JSON menjadi dua lapisan sarang untuk kinerja terbaik
- Pastikan semua bidang yang diperlukan didefinisikan dengan benar
- Validasi skema terhadap spesifikasi Skema JSON

Model tidak menggunakan alat dengan benar

Solusi:

- Pastikan nama alat menjelaskan tujuannya dengan jelas
- Berikan deskripsi rinci tentang fungsionalitas alat
- Secara eksplisit mendefinisikan skema input dengan deskripsi parameter yang jelas
- Sertakan contoh dalam deskripsi saat membantu

Perilaku pemanggilan alat yang tidak konsisten

Solusi: Atur suhu ke 0 untuk pemanggilan alat:

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

Ini memungkinkan decoding serakah untuk penggunaan alat yang lebih andal.

Konflik pilihan alat

Masalah: Kesalahan saat menggunakan alat khusus dengan pencarian web atau penerjemah kode

Solusi: Jangan sertakan ToolSpec khusus dengan nama nova_grounding - ini bertentangan dengan alat sistem. Gunakan konfigurasi alat sistem sebagai gantinya:

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

Masalah Pembumian Web

Masalah kontrol akses

Masalah: Web Grounding dan Code Interpreter tidak berfungsi

Solusi: Pastikan kebijakan IAM Anda meliputi:

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

Masalah Kebijakan Kontrol Layanan

Masalah: Web Grounding diblokir oleh SCP

Solusi: Jika Anda memiliki Kebijakan Kontrol Layanan dengan `aws:requestedRegion` kondisi, perbarui untuk mengizinkan wilayah “tidak ditentukan” untuk fungsionalitas Web Grounding.

Keterbatasan pemrosesan media

Pemahaman yang buruk tentang konten multibahasa dalam gambar/video

Batasan: Model Nova memiliki pemahaman terbatas tentang konten multibahasa di media visual

Solusi:

- Berikan terjemahan teks di samping gambar
- Gunakan input berbasis teks untuk konten multibahasa bila memungkinkan

Identifikasi orang

Masalah: Model menolak untuk mengidentifikasi orang dalam gambar

Perilaku yang Diharapkan: Model akan menolak untuk mengidentifikasi atau memberi nama individu dalam gambar, dokumen, atau video untuk alasan privasi dan keamanan

Solusi: Tanyakan tentang karakteristik atau konteks umum alih-alih identitas tertentu

Keterbatasan penalaran spasial

Masalah: Lokalisasi atau analisis tata letak yang tidak akurat

Batasan: Kemampuan terbatas untuk penalaran spasial yang tepat

Solusi:

- Gunakan deteksi kotak pembatas untuk lokalisasi objek
- Berikan titik referensi yang jelas dalam permintaan Anda
- Pecahkan kueri spasial yang kompleks menjadi komponen yang lebih sederhana

Teks kecil dalam gambar/video

Masalah: Tidak dapat membaca teks kecil di media

Solusi:

- Pangkas gambar untuk fokus pada bagian teks yang relevan
- Meningkatkan Resolusi Media Sumber
- Berikan teks secara terpisah jika tersedia

Penanganan dokumen dan file

Konten yang tidak didukung

Masalah: Pemrosesan PDF gagal

Penyebab:

- PDFs dengan profil warna CMYK
- PDFs berisi gambar SVG

Solusi:

- Konversi PDFs ke profil warna RGB
- Rasterisasi gambar SVG sebelum dimasukkan ke dalam PDFs

Estimasi token

Masalah: Penggunaan token yang tidak terduga dengan PDFs

Pedoman: Perkirakan sekitar 2.560 token per halaman PDF standar 8,5 × 11"

Solusi: Sesuaikan maxTokens sesuai berdasarkan panjang dokumen

Referensi API dan SDK

Bagian ini menyediakan dokumentasi referensi teknis lengkap untuk Amazon Nova APIs dan SDKs.

Topik

- [Skema permintaan dan respons](#)
- [Referensi SDK](#)

Skema permintaan dan respons

Skema permintaan hampir identik antara Invoke API dan Converse API. Perbedaan utama adalah bagaimana data biner (gambar, video, audio) dikodekan: Converse API menggunakan array biner sedangkan Invoke API menggunakan string yang dikodekan Base64.

Struktur permintaan lengkap

Berikut ini menunjukkan struktur permintaan lengkap untuk model Amazon Nova. Semua bidang bersifat opsional kecuali ditandai sebagai wajib:

```
{
  "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"
    }
  }
}

```

Parameter permintaan kunci:

- **system**: Prompt sistem memberikan konteks dan instruksi
- **messages**: Array percakapan berubah dengan peran (pengguna atau asisten) dan konten
- **inferenceConfig**: Mengontrol perilaku keluaran model (suhu, token, dan sebagainya.)

- `toolConfig`: Spesifikasi alat untuk pemanggilan fungsi

Note

Saat menggunakan Converse API, `reasoningConfig` parameter `topK` and harus ditempatkan `additionalModelRequestFields` sebagai ganti. `inferenceConfig`

Bagian berikut memberikan penjelasan rinci dari setiap parameter permintaan:

sistem

`system`— (Opsional) Prompt sistem untuk permintaan. Prompt sistem memberikan konteks dan instruksi ke Amazon Nova, seperti menentukan tujuan atau peran tertentu.

pesan

`messages`— (Wajib) Array pesan masukan yang berisi percakapan berubah.

- `role`— (Wajib) Peran percakapan berubah. Nilai yang valid adalah `user` dan `assistant`. Pesan pertama harus selalu menggunakan `user` peran.
- `content`— (Diperlukan) Sebuah array blok konten. Setiap blok menentukan jenis konten (`text`, `imagevideo`, atau `audio`):
 - `text`— Konten teks untuk giliran percakapan. Jika dikombinasikan dengan gambar atau video, ditafsirkan sebagai teks yang menyertainya.
 - `image`— (Tidak didukung untuk Nova 2 Lite) Konten gambar dengan:
 - `format`- (Diperlukan) Format gambar: `jpeg`, `png`, `webp`, atau `gif`
 - `source.bytes`— (Diperlukan) Data gambar sebagai array biner (Converse API) atau string Base64 (Invoke API)
 - `video`— (Tidak didukung untuk Nova 2 Lite) Konten video dengan:
 - `format`— (Diperlukan) Format video: `mkvmov`, `mp4`, `webm`, `three_gp`, `flv`, `mpeg`, `mpg`, atau `wmv`
 - `source`— (Diperlukan) Sumber video melalui URI S3 (`s3Location.uri` dan `optionalbucketOwner`) atau byte file () `bytes`
 - `audio`— (Amazon Nova Sonic dan hanya) Konten audio dengan:
 - `format`— (Diperlukan) Format audio: `mp3opus`, `wav`, `aac`, `flac`, `mp4`, `ogg`, atau `mkv`
 - `source`- (Diperlukan) Sumber audio melalui URI S3 atau byte file

InferensiConfig

`inferenceConfig`- (Opsional) Parameter konfigurasi yang mengendalikan generasi keluaran model.

- `maxTokens`— (Opsional) Token maksimum untuk dihasilkan sebelum berhenti. Model Amazon Nova dapat berhenti sebelum mencapai batas ini. Nilai maksimum adalah 5.000. Jika tidak ditentukan, menggunakan default dinamis berdasarkan konteks permintaan.
- `temperature`— (Opsional) Keacakan dalam tanggapan. Rentang yang valid: 0,00001-1 (default: 0,7). Nilai yang lebih rendah menghasilkan output yang lebih deterministik.
- `topP`— (Opsional) Ambang pengambilan sampel nukleus. Amazon Nova sampel dari token yang probabilitas kumulatifnya mencapai. `topP` Rentang yang valid: 0-1 (default: 0.9). Sesuaikan salah satu `temperature` atau `topP`, tidak keduanya.
- `topK`— (Opsional) Sampel dari token K teratas saja. Menghapus respons probabilitas rendah. Rentang yang valid: 0-128 (default: tidak digunakan).

Note

Untuk Converse API, teruskan `topK`. `additionalModelRequestFields`

- `stopSequences`— (Opsional) Array string yang menghentikan pembuatan saat ditemui.
- `reasoningConfig`— (Amazon Nova Sonic dan hanya) Konfigurasi penalaran:
 - `type`— (Opsional) `enabled` atau `disabled` (default: `disabled`)
 - `maxReasoningEffort`— Upaya komputasi: `low`, `medium`, atau `high` Dengan `low` dan `medium`, aliran penalaran secara bertahap; `high` menghasilkan penalaran dalam potongan terakhir.

Note

Untuk Converse API, teruskan `reasoningConfig`. `additionalModelRequestFields`

ToolConfig

`toolConfig`- (Opsional) Konfigurasi alat mengikuti [ToolConfiguration skema](#).

- `tools`— Array spesifikasi alat dengan `name`, `description` dan `inputSchema`
- `toolChoice`— (Opsional) Kontrol pemilihan alat:

- **auto**— Model memutuskan apakah dan alat mana yang akan digunakan
- **any**— Model harus menggunakan setidaknya satu alat
- **tool**— Model harus menggunakan alat yang ditentukan dengan nama

Struktur respons lengkap

Berikut ini menunjukkan struktur respons lengkap untuk model Amazon Nova:

```
{
  "ResponseMetadata": {
    "RequestId": "string",
    "HTTPStatusCode": int,
    "HTTPHeaders": {
      "date": "string",
      "content-type": "application/json",
      "content-length": "string",
      "connection": "keep-alive",
      "x-amzn-requestid": "string"
    },
    "RetryAttempts": 0
  },
  "output": {
    "message": {
      "role": "assistant",
      "content": [
        {
          "reasoningContent": { // Optional - if reasoning enabled
            "reasoningText": {
              "text": "[REDACTED]"
            }
          }
        }
      ],
      {
        "toolUse": { // Optional - if tool called
          "toolUseId": "string",
          "name": "string",
          "input": {} // Tool-specific arguments
        }
      }
    },
    {
      "text": "string" // Optional - text response
    }
  }
}
```

```

    },
    {
      "image": { // Optional - Nova 2 Omni only
        "format": "png",
        "source": {
          "bytes": image // Binary array (Converse) or Base64 string (Invoke)
        }
      }
    }
  ]
}
},
"stopReason": "string", // See stop reasons below
"usage": {
  "inputTokens": int,
  "outputTokens": int,
  "totalTokens": int
},
"metrics": {
  "latencyMs": int
}
}

```

Hentikan alasan:

- `end_turn`: Akhir respons alami
- `max_tokens`: Mencapai batas MaxTokens
- `content_filtered`: Kebijakan konten yang dilanggar
- `malformed_model_output`: Output model tidak valid
- `malformed_tool_use`: Output penggunaan alat tidak valid
- `service_unavailable`: Layanan alat bawaan tidak dapat dijangkau
- `invalid_query`: Kueri tidak valid ke alat bawaan
- `max_tool_invocations`: Alat coba lagi habis

Bagian berikut memberikan penjelasan rinci dari setiap bidang respons:

`output`

`output`— (Wajib) Berisi pesan respons model.

- **message**— (Diperlukan) Pesan respons asisten dengan peran dan array konten.
- **content**— (Diperlukan) Array blok konten yang dapat mencakup:
 - **reasoningContent**— (Opsional) Dikembalikan jika penalaran diaktifkan. Berisi teks penalaran, yang akan selalu menjadi [REDACTED] respons.
 - **toolUse**— (Opsional) Dikembalikan jika alat dipanggil. Berisi alat menggunakan ID, nama dan argumen masukan.
 - **text**— (Opsional) Dikembalikan jika model merespons dengan konten teks.
 - **image**— (Opsional, hanya) Dikembalikan jika model menghasilkan gambar. Format akan selalu PNG.

StopReason

stopReason— (Wajib) Menunjukkan mengapa model berhenti menghasilkan output:

- **end_turn**— Akhir respons alami tercapai
- **max_tokens**— Mencapai batas MaxTokens atau batas output maksimum model
- **content_filtered**— Output melanggar kebijakan AI yang Bertanggung Jawab AWS
- **malformed_model_output**— Model menghasilkan output tidak valid
- **malformed_tool_use**— Model menghasilkan alat yang tidak valid menggunakan output
- **service_unavailable**— Layanan alat bawaan tidak dapat dihubungi
- **invalid_query**— Kueri ke alat bawaan tidak valid
- **max_tool_invocations**— Alat bawaan tidak menghasilkan hasil yang valid setelah mencoba ulang

pemakaian

usage— (Diperlukan) Informasi penggunaan Token:

- **inputTokens**— Total token yang dicerna oleh model
- **outputTokens**— Jumlah token yang dihasilkan
- **totalTokens**— Jumlah token input dan output

metrik

metrics— (Diperlukan) Metrik kinerja:

- `latencyMs`— Total waktu penyelesaian inferensi dalam milidetik

Referensi SDK

AWS kit pengembangan perangkat lunak (SDKs) tersedia untuk banyak bahasa pemrograman populer. Setiap SDK menyediakan API, contoh kode, dan dokumentasi yang memudahkan pengembang untuk membangun aplikasi dalam bahasa pilihan mereka.

Dokumentasi SDK	Contoh kode
AWS SDK for C++	AWS Contoh kode SDK for C++
AWS CLI	AWS Contoh kode CLI
AWS SDK for Go	AWS Contoh kode SDK for Go
AWS SDK for Java	AWS Contoh kode SDK for Java
AWS SDK untuk JavaScript	AWS SDK untuk contoh JavaScript kode
AWS SDK para Kotlin	AWS Contoh kode SDK untuk Kotlin
AWS SDK for .NET	AWS Contoh kode SDK for .NET
AWS SDK for PHP	AWS Contoh kode SDK for PHP
AWS Alat untuk PowerShell	AWS Alat untuk contoh PowerShell kode
AWS SDK untuk Python (Boto3)	AWS Contoh kode SDK untuk Python (Boto3)
AWS SDK for Ruby	AWS Contoh kode SDK for Ruby
AWS SDK untuk Rust	AWS Contoh kode SDK untuk Rust
AWS SDK untuk SAP ABAP	AWS Contoh kode SDK untuk SAP ABAP
AWS SDK para Swift	AWS SDK untuk contoh kode Swift

Menyesuaikan model Amazon Nova di AI SageMaker

Anda dapat menyesuaikan model Amazon Nova, termasuk model Amazon Nova 2.0 yang disempurnakan, melalui [resep](#) dan melatihnya SageMaker. Resep-resep ini mendukung teknik seperti fine-tuning (SFT) yang diawasi dan Reinforcement Fine-Tuning (RFT), dengan opsi adaptasi peringkat penuh dan peringkat rendah (LoRa).

Alur kerja end-to-end kustomisasi melibatkan tahapan seperti pelatihan model, evaluasi model, dan penerapan untuk inferensi. Pendekatan penyesuaian model ini SageMaker memberikan fleksibilitas dan kontrol yang lebih besar untuk menyempurnakan model Amazon Nova yang didukung, mengoptimalkan hiperparameter dengan presisi, dan menerapkan teknik seperti fine-tuning hemat parameter LoRa (PEFT), SFT peringkat penuh, RFT, dan Lanjutan Pra-Pelatihan (CPT).

Pendekatan kustomisasi

SageMaker menawarkan dua pendekatan untuk menyesuaikan model Amazon Nova:

Pengalaman berbasis UI - Gunakan untuk menyesuaikan model Amazon Nova melalui antarmuka yang sederhana dan terpandu. Pendekatan ini menyediakan end-to-end alur kerja termasuk pelatihan, evaluasi, dan penyebaran tanpa menulis kode. Pengalaman berbasis UI sangat ideal untuk eksperimen cepat, proof-of-concept pengembangan, dan pengguna yang lebih menyukai alur kerja visual.

Pengalaman berbasis kode — Gunakan SageMaker Python SDK, Nova SDK, dan resep pelatihan untuk menyesuaikan model secara terprogram. Pendekatan ini menawarkan fleksibilitas yang lebih besar, memungkinkan Anda mengonfigurasi hiperparameter tingkat lanjut, berintegrasi dengan CI/CD saluran pipa, dan mengotomatiskan alur kerja pelatihan. Pengalaman berbasis kode direkomendasikan untuk beban kerja produksi, persyaratan penyesuaian yang kompleks, dan tim dengan praktik yang sudah mapan. MLOps

Pendekatan	Terbaik untuk	Manfaat utama
Berbasis UI	Eksperimen, pembuatan prototipe, iterasi cepat	Pengaturan sederhana, alur kerja terpandu, tidak diperlukan pengkodean
Berbasis kode	Produksi, otomatisasi, konfigurasi lanjutan	Fleksibilitas penuh, integrasi pipa, kontrol versi

Platform kustomisasi

AWS menawarkan tiga platform untuk menyesuaikan model Amazon Nova, masing-masing dirancang untuk kasus penggunaan dan persyaratan yang berbeda:

Amazon Bedrock - Menyediakan jalur termudah dan tercepat untuk memodelkan kustomisasi dengan pengaturan minimal. Bedrock menangani semua manajemen infrastruktur secara otomatis, memungkinkan Anda untuk fokus pada data dan kasus penggunaan Anda. Platform ini sangat ideal ketika Anda membutuhkan yang tercepat time-to-value dan lebih menyukai pengalaman yang dikelola sepenuhnya.

SageMaker pekerjaan pelatihan - Menyediakan lingkungan yang dikelola sepenuhnya untuk menyesuaikan model Amazon Nova di mana Anda tidak perlu membuat atau memelihara cluster apa pun. Layanan ini secara otomatis menangani semua penyediaan infrastruktur, penskalaan, dan manajemen sumber daya, sehingga Anda dapat fokus mengonfigurasi parameter pelatihan dan mengirimkan pekerjaan Anda. Platform ini menawarkan keseimbangan antara kemudahan penggunaan dan fleksibilitas, teknik pendukung seperti Parameter Efficient Fine-tuning (PEFT), Full rank fine tuning, dan Reinforcement Fine-Tuning (RFT).

SageMaker HyperPod— Menawarkan lingkungan khusus untuk pelatihan terdistribusi skala besar dengan mengharuskan Anda membuat dan mengelola kluster EKS dengan grup instans terbatas (RIGs). Platform ini memberi Anda fleksibilitas maksimum dalam mengonfigurasi lingkungan pelatihan Anda dengan instans GPU khusus dan Amazon terintegrasi FSx untuk penyimpanan Lustre, membuatnya sangat cocok untuk skenario pelatihan terdistribusi lanjutan, pengembangan model berkelanjutan, dan beban kerja penyesuaian skala perusahaan.

Platform	Kompleksitas	Fleksibilitas	Terbaik untuk
Amazon Bedrock	Terendah	Standar	Kustomisasi tercepat, pengaturan minimal
SageMaker Lowongan Training	Sedang	Tinggi	Fleksibilitas yang seimbang dan kemudahan penggunaan
SageMaker HyperPod	Tertinggi	Maksimum	Pelatihan terdistribusi besar, beban kerja perusahaan

 Note

Jika Anda memberikan kunci KMS ke pekerjaan pelatihan kustomisasi model Amazon Nova Anda untuk enkripsi di bucket S3 keluaran milik Amazon:

- Anda harus memberikan kunci KMS yang sama saat memanggil pekerjaan pelatihan berulang berikutnya, atau saat memanggil Amazon Bedrock CreateCustomModel API yang memanfaatkan model terenkripsi.
- Identitas yang memanggil CreateTrainingJob API (bukan peran eksekusi) harus memiliki izin untuk CreateGrant, RetireGrantEncrypt, dan GenerateDataKey sebagaimana didefinisikan dalam kebijakan kunci KMS.

Prasyarat umum

Proses kustomisasi melibatkan beberapa tahapan kunci termasuk pelatihan model, evaluasi, dan penyebaran untuk inferensi, masing-masing membutuhkan sumber daya dan konfigurasi tertentu. Sebelum memulai kustomisasi model Amazon Nova Anda SageMaker, pastikan Anda memiliki prasyarat umum berikut.

- Sebuah Akun AWS. Jika Anda tidak memilikinya Akun AWS, ikuti [petunjuk ini](#) untuk mendaftar.
- [Menginstal AWS CLI](#) dan [Menyiapkan konfigurasi](#).
- Akses ke [resep kustomisasi model Amazon Nova dasar](#).
- Keakraban file konfigurasi [YAMG](#).
- Keakraban tentang cara menjalankan notebook di lingkungan Anda.
- Keakraban tentang cara membuat AWS sumber daya seperti bucket [Amazon S3](#) dan peran IAM dengan izin yang sesuai.
- Keakraban tentang cara [melatih model dengan SageMaker](#).
- Keakraban [SageMaker HyperPod dengan orkestrasi EKS](#).
- Keakraban [SageMaker HyperPod CLI](#).
- Keakraban model [dasar Amazon Nova](#).
- Keakraban [model Amazon Nova yang tersedia dan algoritma untuk](#) kustomisasi.
- Keakraban inferensi [Amazon Bedrock](#).

Resep Amazon Nova

Anda bisa mendapatkan resep Amazon Nova dari repositori [resep](#). Resep Amazon Nova adalah file [konfigurasi YAMM](#) yang memberikan detail SageMaker tentang cara menjalankan pekerjaan penyesuaian model Anda. Ini memberikan nama model dasar, menetapkan hyperparameters pelatihan, mendefinisikan pengaturan pengoptimalan, dan menyertakan opsi tambahan yang diperlukan untuk menyempurnakan atau melatih model dengan sukses.

Anda juga dapat mengakses resep Amazon Nova melalui SageMaker AI Monarch dan dengan menavigasi ke hub model, memilih AWS, dan menjelajahi model Amazon Nova untuk menemukan resep terkait mereka. Baik SageMaker AI Monarch dan menyediakan contoh buku catatan untuk setiap resep, yang mencakup semua langkah yang diperlukan untuk memodifikasi resep dan menjalankan pekerjaan penyesuaian menggunakan pekerjaan atau SageMaker SageMaker HyperPod lingkungan pelatihan.

Untuk mengakses halaman resep di Amazon SageMaker Studio, peran eksekusi harus memiliki izin berikut.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "s3:GetObject"
      ],
      "Resource": [
        "arn:aws:s3::*model-customization-recipes*"
      ]
    }
  ]
}
```

Untuk menjalankan contoh buku catatan tentang pekerjaan SageMaker pelatihan dan, gunakan salah satu versi gambar SageMaker distribusi berikut: 2.7.1+, 2.8.0+3.2.1+, 3.3.0+. Ini berlaku untuk SageMaker AI Monarch dan.

Topik

- [Mendapatkan resep Amazon Nova](#)
- [Mendapatkan resep Amazon Nova Forge](#)
- [Model dan algoritma yang tersedia](#)
- [Amazon Nova 2.0 Lite](#)

Mendapatkan resep Amazon Nova

Untuk mendapatkan resep dasar Amazon Nova, kloning repositori [resep](#) dengan menjalankan perintah berikut.

```
git clone https://github.com/aws/sagemaker-hyperpod-recipes.git
```

Resep dasar tersedia di [recipes_collection/recipes/](#).

```
cd recipes_collection/recipes/
```

Resep kustomisasi Amazon Nova ada di folder berikut.

Jenis resep	Folder
SFT (peringkat penuh dan PEFT)	fine-tuning/nova
Evaluasi	evaluasi/nova
CPT	pelatihan/nova

Mendapatkan resep Amazon Nova Forge

Untuk mengakses resep Amazon Nova Forge khusus untuk pekerjaan, silakan [atur akses Anda ke Amazon Nova Forge](#) dan kemudian ikuti [lokakarya ini](#) untuk menyiapkan CLI versi Forge.

Untuk Pekerjaan SageMaker Pelatihan, AWS Konsol dan Nova Forge SDK akan secara otomatis mengakses resep Forge.

Model dan algoritma yang tersedia

Tabel berikut merangkum ketersediaan kustomisasi untuk model Amazon Nova dan algoritma yang didukung menggunakan SageMaker

Nama model	ID Model	Penyetelan halus	Catatan
Amazon Nova Lite 2.0	amazon.nova-2-lite-v 1:0:256 k	Ya	• SFT - Menerima and/or gambar teks atau and/or video teks sebagai input dan menghasilkan teks sebagai output. Satu pekerjaan tidak dapat menggabungkan teks, gambar, dan video dalam proses yang sama. • RFT - Menerima teks dan gambar sebagai input untuk percakapan satu putaran dan menghasilkan teks sebagai output. Peningkatan kemampuan pengoptimalan hadiah. • CPT

Amazon Nova 2.0 Lite

Tabel di bawah ini mencantumkan informasi rinci tentang referensi resep Amazon Nova 2.0 Lite.

Model	Kategori/ sub- kategori	Teknik	Nama Resep	Image URI (Lowongan Pelatihan)	Gambar URI (SageMaker HyperPod)	Instans Komputasi
Nova 2.0 Lite	Pelatihan	Pelatihan Pra Lanjutan	nova_lite _2_0_p5x8 _gpu_pret rain.yaml	N/A	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-CPT-V2-latest	ml.p5.48xlarge , ml.p5en.48xlarge
Nova 2.0 Lite	Paramete Penyetela n Halus yang Efisien	Penyetelan Halus	nova_lite _2_0_p5_g pu_lora_sft.yaml	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-TJ-SFT-V2-latest	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-SFT-V2-latest	ml.p5.48xlarge , ml.p5en.48xlarge

Model	Kategori/ sub- kategori	Teknik	Nama Resep	Image URI (Lowongan Pelatihan)	Gambar URI (SageMaker HyperPod)	Instans Komputasi
Nova 2.0 Lite	Penyetelan Halus Peringkat Penuh	Penyetelan Halus	nova_lite_2_0_p5_gpu_sft.yaml	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-TJ-SFT-V2-latest	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-SFT-V2-latest	ml.p5.48xlarge, ml.p5en.48xlarge

Model	Kategori/ sub- kategori	Teknik	Nama Resep	Image URI (Lowongan Pelatihan)	Gambar URI (SageMaker HyperPod)	Instans Komputasi
Nova 2.0 Lite	Parameter RFT Efisien	Penyetelan Halus	nova_lite _v2_smtj_ p5_p5en_g pu_lora_rft.yaml	708977205 387.dkr.ecr.us- east-1.amazonaws.com/ nova- fine- tune-rep o:SM-TJ- RFT-V2- latest	708977205 387.dkr.ecr.us- east-1.amazonaws.com/ nova- fine- tune- rep o:SM- HP-R FT- TRAIN- V2- latest	ml.p5.48x large , ml.p5en.4 8xlarge

Model	Kategori/ sub- kategori	Teknik	Nama Resep	Image URI (Lowongan Pelatihan)	Gambar URI (SageMaker HyperPod)	Instans Komputasi
Nova 2.0 Lite	RFT Peringkat Penuh	Penyetelan Halus	nova_lite_v2_smtj_p5en_gpu_rft.yaml	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-TJ-RFT-V2-latest	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-RFT-TRAIN-V2-latest	ml.p5.48xlarge, ml.p5en.48xlarge

Model	Kategori/ sub- kategori	Teknik	Nama Resep	Image URI (Lowongan Pelatihan)	Gambar URI (SageMaker HyperPod)	Instans Komputasi
Nova 2.0 Lite	Bawa Data Anda Sendiri	Evaluasi	nova_lite _2_0_p5_4 8x1_gpu_b ring_your _own_data set_eval.yaml	708977205 387.dkr.ecr.us- east-1.amazo naws.com/ nova- eval uation- repo:SM- TJ-Eval- V2-1 atest	708977205 387.dkr.ecr.us- east-1.amazo naws.com/ nova- eval uation- repo:SM- HP- Eval- V2-1 atest	ml.p5.48x large , ml.p5en.4 8xlarge

Model	Kategori/ sub- kategori	Teknik	Nama Resep	Image URI (Lowongan Pelatihan)	Gambar URI (SageMaker HyperPod)	Instans Komputasi
Nova 2.0 Lite	Tolok Ukur Teks Umum	Evaluasi	nova_lite_2_0_p5_48x1_gpu_general_text_benchmark_ark_eval.yaml	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-TJ-Eval-V2-1-atest	708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-HP-Eval-V2-1-atest	ml.p5.48xlarge, ml.p5en.48xlarge

Model	Kategori/ sub- kategori	Teknik	Nama Resep	Image URI (Lowongan Pelatihan)	Gambar URI (SageMaker HyperPod)	Instans Komputasi
Nova 2.0 Lite	Evaluasi RFT	Evaluasi	nova_lite _2_0_p5_4 8x1_gpu_r ft_eval.yaml	708977205 387.dkr.ecr.us- eas t-1.amazonaws.com/ nova- eval uation- repo:SM- TJ-Eval- V2-1 atest	708977205 387.dkr.ecr.us- eas t-1.amazonaws.com/ nova- eval uation- re po:SM- HP- Eval- V2-1 atest	ml.p5.48x large , ml.p5en.4 8xlarge

Model	Kategori/ sub- kategori	Teknik	Nama Resep	Image URI (Lowongan Pelatihan)	Gambar URI (SageMaker HyperPod)	Instans Komputasi
Nova 2.0 Lite	Hakim Berbasis Rubrik LLM	Evaluasi	nova_lite _2_0_p5_4 8x1_gpu_r ubric_llm _judge_eval.yaml	708977205 387.dkr.e cr.us- eas t-1.amazo naws.com/ nova- eval uation- repo:SM- TJ-Eval- V2-1 atest	708977205 387.dkr.e cr.us- eas t-1.amazo naws.com, nova- eval uation- re po:SM- HP- Eval- V2-1 atest	m1.p5.48x large , m1.p5en.4 8xlarge

Kustomisasi Amazon Nova pada Pekerjaan SageMaker Pelatihan

SageMaker Training Jobs adalah lingkungan yang memungkinkan Anda melatih model pembelajaran mesin dalam skala besar. Ini secara otomatis menyediakan dan menskalakan sumber daya komputasi, memuat data pelatihan dari sumber seperti Amazon S3, mengeksekusi kode pelatihan Anda, dan menyimpan artefak model yang dihasilkan.

Tujuan pelatihan adalah untuk menyesuaikan model Amazon Nova dasar menggunakan data milik Anda. Proses pelatihan biasanya melibatkan langkah-langkah untuk menyiapkan data Anda, memilih [resep](#), memodifikasi parameter konfigurasi dalam file YAMM, dan mengirimkan pekerjaan pelatihan. Proses pelatihan akan menampilkan pos pemeriksaan model terlatih dalam bucket Amazon S3 yang dikelola layanan. Anda dapat menggunakan lokasi pos pemeriksaan ini untuk pekerjaan evaluasi. Kustomisasi Nova pada pekerjaan pelatihan SageMaker AI menyimpan artefak model dalam ember Amazon S3 yang dikelola layanan. Artefak dalam bucket yang dikelola layanan dienkripsi dengan

kunci KMS yang dikelola AI. SageMaker Bucket Amazon S3 yang dikelola layanan saat ini tidak mendukung enkripsi data menggunakan kunci KMS yang dikelola pelanggan.

Praktik Terbaik untuk kustomisasi Amazon Nova

Ikhtisar

Bagian ini memberikan ikhtisar teknik penyesuaian dan membantu Anda memilih pendekatan terbaik untuk kebutuhan dan data yang tersedia.

Dua tahap pelatihan LLM

Pelatihan model bahasa besar terdiri dari dua tahap utama: pra-pelatihan dan pasca pelatihan. Selama pra-pelatihan, model memproses token teks mentah dan mengoptimalkan prediksi token berikutnya. Proses ini menciptakan pelengkap pola yang menyerap sintaks, semantik, fakta, dan pola penalaran dari web dan teks yang dikuratori. Namun, model yang telah dilatih sebelumnya tidak memahami instruksi, tujuan pengguna, atau perilaku yang sesuai dengan konteks. Ini melanjutkan teks dalam gaya apa pun yang sesuai dengan distribusi pelatihannya. Model pra-terlatih melengkapi secara otomatis daripada mengikuti petunjuk, menghasilkan pemformatan yang tidak konsisten, dan dapat mencerminkan bias yang tidak diinginkan atau konten yang tidak aman dari data pelatihan. Pra-pelatihan membangun kompetensi umum, bukan kegunaan tugas.

Pasca-pelatihan mengubah pelengkap pola menjadi asisten yang berguna. Anda menjalankan beberapa putaran Supervised Fine-Tuning (SFT) untuk mengajarkan model mengikuti instruksi, mematuhi skema dan kebijakan, memanggil alat, dan menghasilkan output yang andal dengan meniru demonstrasi berkualitas tinggi. Penyelarasan ini mengajarkan model untuk menanggapi permintaan sebagai tugas daripada teks untuk melanjutkan. Anda kemudian menerapkan Reinforcement Fine-Tuning (RFT) untuk mengoptimalkan perilaku menggunakan umpan balik yang terukur (seperti verifier atau an LLM-as-a-judge), menyeimbangkan trade-off seperti akurasi versus singkatnya, keamanan versus cakupan, atau penalaran multi-langkah di bawah kendala. Dalam praktiknya, Anda mengganti SFT dan RFT dalam siklus untuk membentuk model yang telah dilatih sebelumnya menjadi sistem yang andal dan selaras dengan kebijakan yang melakukan tugas-tugas kompleks secara konsisten.

Pilih pendekatan kustomisasi yang tepat

Pada bagian ini kita akan membahas strategi penyesuaian pasca pelatihan: RFT dan SFT.

Penyetelan halus penguatan (RFT)

Penyetelan halus penguatan meningkatkan kinerja model melalui sinyal umpan balik — skor terukur atau penghargaan yang menunjukkan kualitas respons — daripada pengawasan langsung dengan jawaban yang benar dan tepat. Tidak seperti fine-tuning tradisional yang diawasi yang belajar dari pasangan input-output, RFT menggunakan fungsi hadiah untuk mengevaluasi respons model dan secara iteratif mengoptimalkan model untuk memaksimalkan penghargaan ini. Pendekatan ini bekerja dengan baik untuk tugas-tugas di mana mendefinisikan output yang benar secara tepat menantang, tetapi Anda dapat mengukur kualitas respons dengan andal. RFT memungkinkan model untuk mempelajari perilaku dan preferensi yang kompleks melalui uji coba dan umpan balik, menjadikannya ideal untuk aplikasi yang memerlukan pengambilan keputusan bernuansa, pemecahan masalah yang kreatif, atau kepatuhan terhadap kriteria kualitas tertentu yang dapat Anda evaluasi secara terprogram. Misalnya, menjawab pertanyaan hukum yang kompleks adalah kasus penggunaan yang ideal untuk RFT karena Anda ingin mengajarkan model bagaimana bernalar lebih baik untuk menjawab pertanyaan dengan lebih akurat.

Cara kerjanya

Dalam penyempurnaan penguatan, Anda mulai dari garis dasar yang disetel instruksi dan memperlakukan setiap prompt seperti turnamen kecil. Untuk masukan yang diberikan, Anda mengambil sampel beberapa jawaban kandidat dari model, menilai masing-masing dengan fungsi hadiah, lalu memberi peringkat dalam kelompok itu. Langkah pembaruan mendorong model untuk membuat kandidat dengan skor lebih tinggi lebih mungkin di lain waktu dan yang mendapat skor lebih rendah lebih kecil kemungkinannya, sementara stay-close-to-baseline kendala membuat perilaku tidak melayang atau menjadi bertele-tele atau eksploitatif. Anda mengulangi loop ini melalui banyak petunjuk, menyegarkan hard case, mengencangkan verifier atau menilai rubrik saat Anda melihat eksploitasi, dan terus melacak metrik tugas.

Kapan menggunakan RFT

Tugas yang paling diuntungkan dari RFT memiliki beberapa sifat. Mereka memiliki sinyal keberhasilan yang terukur bahkan ketika satu output yang benar sulit ditentukan. Mereka mengakui kredit sebagian atau kualitas bertingkat sehingga Anda dapat memberi peringkat yang lebih baik dibandingkan jawaban yang lebih buruk dalam prompt atau menggunakan fungsi hadiah. Mereka melibatkan beberapa tujuan yang harus seimbang (seperti akurasi dengan singkatnya, kejelasan, keamanan, atau biaya). Mereka membutuhkan kepatuhan terhadap batasan eksplisit yang dapat Anda periksa secara terprogram. Mereka beroperasi dalam pengaturan yang dimediasi alat atau berbasis lingkungan di mana hasil dapat diamati (keberhasilan atau kegagalan, latensi, penggunaan sumber daya). Mereka terjadi dalam rezim label rendah di mana mengumpulkan target emas mahal

tetapi umpan balik otomatis atau berbasis rubrik berlimpah. RFT bekerja paling baik ketika Anda dapat mengubah kualitas menjadi skalar atau peringkat yang andal dan ingin model tersebut secara istimewa memperkuat perilaku dengan skor lebih tinggi tanpa memerlukan target berlabel lengkap.

Pertimbangkan metode lain ketika:

- Anda memiliki pasangan input-output berlabel yang berlimpah dan andal - Gunakan SFT
- Kesenjangan utama adalah pengetahuan atau jargon — Gunakan retrieval-augmented generation (RAG)
- Sinyal hadiah Anda berisik atau tidak dapat diandalkan dan Anda tidak dapat memperbaikinya dengan rubrik atau catur yang lebih baik — Stabilkan itu terlebih dahulu sebelum RFT

Kapan tidak menggunakan RFT

Hindari RFT dalam situasi ini:

- Anda dapat dengan mudah menghasilkan pasangan input-output berlabel yang andal (SFT lebih sederhana, lebih murah, dan lebih stabil)
- Kesenjangan adalah pengetahuan atau jargon daripada perilaku (gunakan RAG)
- Sinyal hadiah Anda berisik, jarang, mudah dimainkan, atau mahal atau lambat untuk dihitung (perbaiki evaluator terlebih dahulu)
- Kinerja dasar mendekati nol (bootstrap dengan SFT sebelum mengoptimalkan preferensi)
- Tugas ini memiliki skema deterministik, pemformatan ketat, atau satu jawaban yang benar (SFT atau validasi berbasis aturan bekerja lebih baik)
- Latensi ketat atau anggaran biaya tidak dapat menyerap pengambilan sampel tambahan atau eksplorasi yang dibutuhkan RFT
- Kendala keamanan atau kebijakan tidak ditentukan secara jelas dan dapat ditegakkan dalam hadiah

Jika Anda dapat menunjuk ke “jawaban yang benar,” gunakan SFT. Jika Anda membutuhkan pengetahuan baru, gunakan RAG. Gunakan RFT hanya setelah Anda memiliki baseline yang solid dan fungsi hadiah yang kuat, hard-to-exploit cepat.

Penyetelan halus yang diawasi (SFT)

Penyetelan halus yang diawasi melatih LLM pada kumpulan data pasangan input-output berlabel manusia untuk tugas Anda. Anda memberikan contoh petunjuk (pertanyaan, instruksi, dan

sebagainya) dengan tanggapan yang benar atau diinginkan, dan terus melatih model pada contoh-contoh ini. Model menyesuaikan bobotnya untuk meminimalkan kerugian yang diawasi (biasanya lintas entropi antara prediksi dan token keluaran target). Ini adalah pelatihan yang sama yang digunakan dalam sebagian besar tugas pembelajaran mesin yang diawasi, diterapkan untuk mengkhususkan LLM.

SFT mengubah perilaku, bukan pengetahuan. Itu tidak mengajarkan model fakta atau jargon baru yang tidak dilihatnya dalam pra-pelatihan. Ini mengajarkan model bagaimana menjawab, bukan apa yang harus diketahui. Jika Anda membutuhkan pengetahuan domain baru (seperti terminologi internal), gunakan retrieval-augmented generation (RAG) untuk menyediakan konteks itu pada waktu inferensi. SFT kemudian menambahkan perilaku mengikuti instruksi yang diinginkan di atas.

Cara kerjanya

SFT mengoptimalkan LLM dengan meminimalkan kerugian lintas entropi rata-rata pada token respons, memperlakukan token prompt sebagai konteks dan menutupinya dari kerugian. Model menginternalisasi gaya target, struktur, dan aturan keputusan Anda, belajar untuk menghasilkan penyelesaian yang benar untuk setiap prompt. Misalnya, untuk mengklasifikasikan dokumen ke dalam kategori kustom, Anda menyempurnakan model dengan petunjuk (teks dokumen) dan pelengkapan berlabel (label kategori). Anda melatih pasangan tersebut sampai model mengeluarkan label yang tepat untuk setiap prompt dengan probabilitas tinggi.

Anda dapat melakukan SFT dengan sedikitnya beberapa ratus contoh dan skala hingga beberapa ratus ribu. Sampel SFT harus berkualitas tinggi dan langsung selaras dengan perilaku model yang diinginkan.

Kapan menggunakan SFT

Gunakan SFT ketika Anda memiliki tugas yang terdefinisi dengan baik dengan output yang diinginkan dengan jelas. Jika Anda dapat secara eksplisit menyatakan “Diberikan input X, output yang benar adalah Y” dan mengumpulkan contoh pemetaan tersebut, fine-tuning yang diawasi adalah pilihan yang baik. SFT unggul dalam skenario ini:

- Tugas klasifikasi terstruktur atau kompleks - Klasifikasi dokumen atau kontrak internal ke dalam banyak kategori khusus. Dengan SFT, model mempelajari kategori spesifik ini lebih baik daripada mendorong saja.
- Tugas penjawab pertanyaan atau transformasi dengan jawaban yang diketahui - Sempurnakan model untuk menjawab pertanyaan dari basis pengetahuan perusahaan, atau mengonversi data antar format di mana setiap input memiliki respons yang benar.

- Pemformatan dan konsistensi gaya - Latih model untuk selalu merespons dalam format atau nada tertentu dengan menyempurnakan contoh format atau nada yang benar. Misalnya, pelatihan pada pasangan respons cepat yang menunjukkan suara merek tertentu mengajarkan model untuk menghasilkan output dengan gaya itu. Perilaku mengikuti instruksi sering kali awalnya diajarkan melalui SFT pada contoh perilaku asisten yang baik yang dikuratori.

SFT adalah cara paling langsung untuk mengajarkan LLM keterampilan atau perilaku baru ketika Anda dapat menentukan seperti apa perilaku yang benar. Ini menggunakan pemahaman bahasa model yang ada dan memfokuskannya pada tugas Anda. Gunakan SFT ketika Anda ingin model melakukan hal tertentu dan Anda memiliki atau dapat membuat kumpulan data contoh.

Gunakan SFT saat Anda dapat merakit pasangan prompt dan respons berkualitas tinggi yang mencerminkan perilaku yang Anda inginkan. Ini cocok dengan tugas dengan target yang jelas atau format deterministik seperti skema, fungsi atau panggilan alat, dan jawaban terstruktur di mana imitasi adalah sinyal pelatihan yang sesuai. Tujuannya adalah membentuk perilaku: mengajarkan model untuk memperlakukan petunjuk sebagai tugas, mengikuti instruksi, mengadopsi kebijakan nada dan penolakan, dan menghasilkan pemformatan yang konsisten. Rencanakan setidaknya ratusan demonstrasi, dengan kualitas data, konsistensi, dan deduplikasi lebih penting daripada volume mentah. Untuk pembaruan yang mudah dan hemat biaya, gunakan metode hemat parameter seperti Adaptasi Peringkat Rendah untuk melatih adaptor kecil sambil membiarkan sebagian besar tulang punggung tidak tersentuh.

Kapan tidak menggunakan SFT

Jangan gunakan SFT ketika kesenjangan adalah pengetahuan daripada perilaku. Itu tidak mengajarkan model fakta baru, jargon, atau peristiwa baru-baru ini. Dalam kasus tersebut, gunakan generasi tambahan pengambilan untuk membawa pengetahuan eksternal pada kesimpulan. Hindari SFT ketika Anda dapat mengukur kualitas tetapi tidak dapat memberi label satu jawaban yang benar. Gunakan penyetelan penguatan dengan imbalan yang dapat diverifikasi atau untuk mengoptimalkan hadiah tersebut LLM-as-a-judge secara langsung. Jika kebutuhan atau konten Anda sering berubah, andalkan pengambilan dan penggunaan alat daripada melatih ulang model.

Topik

- [Nova Forge SDK](#)
- [Pelatihan untuk model Amazon Nova](#)
- [Memantau Kemajuan di Seluruh Iterasi](#)
- [Mengevaluasi model terlatih SageMaker AI Anda](#)

- [Pelatihan berulang](#)

Nova Forge SDK

Nova Forge SDK adalah SDK Python komprehensif untuk menyesuaikan model Amazon Nova. SDK menyediakan antarmuka terpadu untuk pelatihan, evaluasi, pemantauan, penyebaran, dan inferensi model Amazon Nova di berbagai platform termasuk SageMaker AI dan Amazon Bedrock. Baik Anda mengadaptasi model ke tugas khusus domain atau mengoptimalkan kinerja untuk kasus penggunaan Anda, SDK ini menyediakan semua yang Anda butuhkan dalam satu antarmuka terpadu.

Manfaat

- Satu SDK untuk seluruh siklus hidup kustomisasi model—mulai dari persiapan data hingga penerapan dan pemantauan.
- Dukungan untuk beberapa metode pelatihan termasuk lanjutan pra-pelatihan (CPT), penyetelan halus yang diawasi (SFT), optimasi preferensi langsung (DPO), dan penyetelan halus penguatan (RFT), baik putaran tunggal maupun multi-putaran, dengan LoRa dan pendekatan peringkat penuh.
- Dukungan bawaan untuk Pekerjaan SageMaker Pelatihan, SageMaker HyperPod, dan Amazon Bedrock, dengan manajemen sumber daya otomatis.
- Tidak perlu lagi menemukan resep atau URI wadah yang tepat untuk teknik pelatihan Anda.
- Bawa resep pelatihan Anda sendiri atau gunakan default cerdas SDK dengan penggantian parameter.
- SDK memvalidasi konfigurasi Anda terhadap kombinasi model dan instance yang didukung dan menyediakan dukungan validasi, mencegah kesalahan sebelum pelatihan dimulai.
- CloudWatch Pemantauan Amazon terintegrasi memungkinkan Anda melacak kemajuan pelatihan secara real-time.
- Terintegrasi MLFlow untuk melacak eksperimen pelatihan dengan server MLFlow pelacak SageMaker AI.

Persyaratan

SDK membutuhkan setidaknya Python 3.12.

Penginstalan

Untuk menginstal SDK ini, ikuti perintah di bawah ini.

```
pip install amzn-nova-forge
```

Model dan Teknik yang Didukung

SDK mendukung model dan teknik berikut dalam keluarga Amazon Nova:

Metode	Model yang Didukung
Lanjutan Pra-pelatihan	Semua Model Nova (hanya SMHP)
LoRa Fine-tuning yang diawasi	Semua Model Nova
Peringkat Penuh Fine-tuning yang Diawasi	Semua Model Nova (hanya SMHP dan SMTJ)
Optimasi Preferensi Langsung LoRa	Model Nova 1.0 (hanya SMHP dan SMTJ)
Optimasi Preferensi Langsung Peringkat Penuh	Model Nova 1.0 (hanya SMHP dan SMTJ)
Penguatan Fine-tuning LoRa	Nova Lite 2.0
Penguatan Fine-tuning Peringkat Penuh	Nova Lite 2.0 (hanya SMHP dan SMTJ)
LoRa Fine-tuning Penguatan Multi-putaran	Nova Lite 2.0 (Hanya SMHP)
Penguatan Multi-putaran Fine-tuning Peringkat Penuh	Nova Lite 2.0 (Hanya SMHP)

Memulai

Topik

- [1. Siapkan Data Anda](#)
- [2. Konfigurasi Infrastruktur Anda](#)
- [3. Melatih](#)
- [4. Memantau](#)
- [5. Evaluasi](#)
- [6. Deploy](#)

1. Siapkan Data Anda

Muat kumpulan data Anda dari file lokal atau S3, dan biarkan SDK menangani transformasi ke format yang benar untuk metode pelatihan yang Anda pilih. Atau, berikan data yang diformat dan segera mulai.

```
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. Konfigurasi Infrastruktur Anda

Pilih sumber daya komputasi Anda—SDK memvalidasi konfigurasi dan memastikan penyiapan yang optimal.

```
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. Melatih

Mulai pelatihan hanya dengan beberapa baris kode.


```
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. Memantau

Lacak kemajuan latihan Anda langsung dari SDK.

```
from amzn_nova_forge.monitor.log_monitor import CloudWatchLogMonitor

# Monitor training logs
customizer.get_logs()

# Or monitor directly via CloudWatchLogMonitor
monitor = CloudWatchLogMonitor.from_job_result(result)
monitor.show_logs(limit=10)

# Check job status
result.get_job_status() # InProgress, Completed, Failed
```

5. Evaluasi

Evaluasi kinerja model dengan berbagai [tolok ukur bawaan](#), atau rancang evaluasi Anda sendiri.

```
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. Deploy

Terapkan model khusus Anda ke produksi dengan dukungan bawaan untuk Amazon Bedrock atau SageMaker

```
from amzn_nova_forge.model.model_enums import DeployPlatform

# Bedrock provisioned throughput
deployment = customizer.deploy(
    model_artifact_path=result.model_artifacts.checkpoint_s3_path,
    deploy_platform=DeployPlatform.BEDROCK_PT,
    pt_units=10
)

# Bedrock On-Demand
deployment = customizer.deploy(
    model_artifact_path=result.model_artifacts.checkpoint_s3_path,
    deploy_platform=DeployPlatform.BEDROCK_OD,
    pt_units=10
)

# Sagemaker Real-time Inference
deployment = customizer.deploy(
    model_artifact_path=result.model_artifacts.checkpoint_s3_path,
    deploy_platform=DeployPlatform.SAGEMAKER,
    unit_count=10,
    sagemaker_instance_type="ml.p5.48xlarge",
    sagemaker_environment_variables={
        "CONTEXT_LENGTH": "12000",
        "MAX_CONCURRENCY": "16",
    }
)
```

Kemampuan Kunci

Penciptaan Resep On The Fly

SDK menghilangkan kebutuhan untuk mencari resep atau URI wadah yang sesuai untuk teknik tertentu.

Pemrosesan Data Cerdas

SDK secara otomatis mengubah data Anda menjadi format yang benar untuk pelatihan. Baik Anda bekerja dengan file JSON, JSONL, atau CSV, pemuat data menangani konversi dengan mulus. Data Loader mendukung teks serta data multimodal (gambar dan video).

Dukungan Infrastruktur Perusahaan

SDK bekerja dengan kedua Pekerjaan SageMaker Pelatihan dan SageMaker HyperPod, secara otomatis mengelola:

- Validasi tipe instans
- Validasi resep
- Validasi kumpulan data
- Orkestrasi dan pemantauan Job

SDK juga mendukung SageMaker Training Jobs tanpa server dan kustomisasi Bedrock.

Evaluasi komprehensif

Evaluasi model khusus Anda terhadap [tolok ukur standar](#) termasuk:

- MMLU (Pemahaman Bahasa Multitask Besar-besaran)
- BBH (Tugas Penalaran Tingkat Lanjut)
- GPQA (Tanya Jawab Bukti Google Tingkat Pascasarjana)

Baik menggunakan default benchmark, atau memodifikasinya agar sesuai dengan kebutuhan Anda:

- BYOM (Bawa Metrik Anda Sendiri)
- BYOD (Bawa Dataset Anda Sendiri)

Penyebaran Produksi

Terapkan model Anda ke Amazon Bedrock atau SageMaker AI dengan opsi untuk:

- Bedrock Provisioned Throughput - Kapasitas khusus untuk kinerja yang konsisten
- Bedrock On-Demand (hanya berlaku untuk kustomisasi berbasis LoRa) - harga Pay-per-use

- SageMaker Inferensi Real-time AI - Kapasitas khusus untuk kinerja yang konsisten

Inferensi Batch

Jalankan pekerjaan inferensi skala besar secara efisien:

- Memproses ribuan permintaan secara paralel
- Agregasi hasil otomatis
- Pemrosesan batch hemat biaya

Nova Forge

Untuk pelanggan Nova Forge, SDK mendukung resep pencampuran data.

Pelajari Lebih Lanjut

Siap untuk mulai menyesuaikan model Nova dengan Nova Forge SDK? Lihat GitHub repositori kami untuk panduan terperinci, referensi API, dan contoh tambahan: <https://github.com/aws/nova-forge-sdk>

Pelatihan untuk model Amazon Nova

Melatih model Amazon Nova tentang Pekerjaan SageMaker Pelatihan mendukung Supervised Fine-Tuning (SFT) dan Reinforcement Fine-Tuning (RFT). Setiap teknik melayani kebutuhan kustomisasi yang berbeda dan dapat diterapkan ke versi model Amazon Nova yang berbeda.

Topik

- [Sempurnakan Nova 2.0](#)
- [Reinforcement Fine-Tuning \(RFT\) dengan model Amazon Nova](#)

Sempurnakan Nova 2.0

Prasyarat

Sebelum Anda memulai pekerjaan pelatihan, perhatikan hal berikut.

- Bucket Amazon S3 untuk menyimpan data input dan output pekerjaan pelatihan Anda. Anda dapat menggunakan satu bucket untuk keduanya atau ember terpisah untuk setiap jenis data. Pastikan ember Anda berada di tempat yang sama di Wilayah AWS mana Anda membuat semua sumber daya lain untuk pelatihan. Untuk informasi selengkapnya, lihat [Membuat bucket tujuan umum](#).

- Peran IAM dengan izin untuk menjalankan pekerjaan pelatihan. Pastikan Anda melampirkan kebijakan IAM dengan `AmazonSageMakerFullAccess`. Untuk informasi selengkapnya, lihat [Cara menggunakan peran eksekusi SageMaker AI](#).
- Resep dasar Amazon Nova, lihat [???](#).

Apa itu SFT?

Supervised fine-tuning (SFT) melatih model bahasa menggunakan pasangan input-output berlabel. Model belajar dari contoh demonstrasi yang terdiri dari petunjuk dan tanggapan, menyempurnakan kemampuannya untuk menyelaraskan dengan tugas, instruksi, atau perilaku yang diinginkan tertentu.

Persiapan data

Ikhtisar

Data Nova 2.0 SFT menggunakan format Converse API yang sama dengan Nova 1.0, dengan penambahan bidang konten penalaran opsional. Untuk spesifikasi format lengkap, lihat:

- Konten penalaran: [ReasoningContentBlock](#)
- [Skema API Converse: API Converse](#)
- [Kendala set data: Kendala set data](#)

Fitur yang didukung

- Jenis input - Teks, gambar, atau video di blok konten pengguna
- Konten asisten - Tanggapan khusus teks dan konten penalaran
- Komposisi dataset — Harus homogen. Pilih salah satu dari:
 - Giliran hanya teks
 - Teks+gambar berubah
 - Teks+video berubah (mendukung pemahaman dokumen)

Important

Anda tidak dapat mencampur gambar dan video dalam kumpulan data yang sama atau di belokan yang berbeda.

Keterbatasan saat ini

- Konten penalaran multimodal - Meskipun format Converse mendukung konten penalaran berbasis gambar, Nova 2.0 SFT hanya mendukung konten penalaran berbasis teks di bidang ReasoningText.
- Set validasi - Anda tidak dapat memberikan kumpulan data validasi untuk SFT dengan Nova 2.0. Jika Anda memberikan kumpulan data validasi, itu akan diabaikan selama pelatihan. Batasan ini berlaku untuk pengajuan pekerjaan berbasis UI dan terprogram.

Format media yang didukung

- Gambar - PNG, JPEG, GIF
- Video - MOV, MKV, MP4

Contoh format data

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"
}
```

Panggilan alat

Nova 2.0 SFT mendukung model pelatihan tentang pola pemanggilan alat, memungkinkan model Anda mempelajari kapan dan bagaimana memanggil alat atau fungsi eksternal.

Format data untuk pemanggilan alat

Data pelatihan pemanggilan alat mencakup `toolConfig` bagian yang mendefinisikan alat yang tersedia, bersama dengan giliran percakapan yang menunjukkan pola penggunaan alat.

Masukan sampel

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

Persyaratan panggilan alat

Saat membuat data pelatihan pemanggilan alat, ikuti persyaratan ini:

Persyaratan	Deskripsi
ToolUse penempatan	ToolUse harus muncul di asisten giliran saja
ToolResult penempatan	ToolResult harus muncul di giliran pengguna saja
ToolResult format	ToolResult harus berupa teks atau JSON saja. Modalitas lain tidak didukung untuk model Nova
Format InputSkema	InputSchema dalam ToolSpec harus berupa objek Skema JSON yang valid
toolUseId pencocokan	Masing-masing ToolResult harus mereferensikan yang valid toolUseId dari asisten sebelumnya ToolUse, dengan masing-masing toolUseId digunakan tepat sekali per percakapan

Catatan penting

- Pastikan definisi alat Anda konsisten di semua sampel pelatihan
- Model mempelajari pola pemanggilan alat dari demonstrasi yang Anda berikan

- Sertakan beragam contoh kapan harus menggunakan setiap alat dan kapan tidak menggunakan alat

Pemahaman dokumen

Nova 2.0 SFT mendukung pelatihan tentang tugas berbasis dokumen, memungkinkan model Anda mempelajari cara menganalisis dan menanggapi pertanyaan tentang dokumen PDF.

Format data untuk pemahaman dokumen

Data pelatihan pemahaman dokumen mencakup referensi dokumen di blok konten pengguna, dengan model pembelajaran untuk mengekstrak dan memberi alasan atas konten dokumen.

Masukan sampel

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

Keterbatasan pemahaman dokumen

Batasan	Detail
Format yang didukung	Hanya file PDF
Ukuran dokumen maksimum	10 MB
Pencampuran modalitas	Sampel dapat memiliki dokumen dan teks, tetapi tidak dapat memiliki dokumen yang dicampur dengan modalitas lain (gambar, video)

Praktik terbaik untuk memahami dokumen

- Pastikan dokumen diformat dengan jelas dan teks dapat diekstraksi
- Berikan beragam contoh yang mencakup berbagai jenis dokumen dan format pertanyaan
- Sertakan konten penalaran untuk membantu model mempelajari pola analisis dokumen

Pemahaman video

Nova 2.0 SFT mendukung pelatihan tentang tugas berbasis video, memungkinkan model Anda mempelajari cara menganalisis dan menanggapi pertanyaan tentang konten video.

Format data untuk pemahaman video

Data pelatihan pemahaman video mencakup referensi video di blok konten pengguna, dengan model pembelajaran untuk mengekstrak informasi dan alasan atas konten video.

Masukan sampel

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

Keterbatasan pemahaman video

Batasan	Detail
Ukuran video maksimal	50 MB
Durasi video maksimum	15 menit
Video per sampel	Hanya satu video yang diizinkan per sampel. Beberapa video dalam sampel yang sama tidak didukung
Pencampuran modalitas	Sampel dapat memiliki video dan teks, tetapi tidak dapat memiliki video yang digabungkan dengan modalitas lain (gambar, dokumen)

Format video yang didukung

- MOV
- MKV
- MP4

Praktik terbaik untuk memahami video

- Jaga agar video tetap ringkas dan fokus pada konten yang relevan dengan tugas Anda
- Pastikan kualitas video cukup bagi model untuk mengekstrak informasi yang bermakna
- Berikan pertanyaan yang jelas yang mereferensikan aspek-aspek spesifik dari konten video
- Sertakan beragam contoh yang mencakup berbagai jenis video dan format pertanyaan

Mode penalaran vs non-penalaran

Memahami konten penalaran

Konten penalaran (juga disebut chain-of-thought) menangkap langkah-langkah pemikiran menengah model sebelum menghasilkan jawaban akhir. Pada `assistant` gilirannya, gunakan `reasoningContent` bidang untuk memasukkan jejak penalaran ini.

Bagaimana kerugian dihitung

- Dengan konten penalaran — Kerugian pelatihan mencakup token penalaran dan token keluaran akhir
- Tanpa penalaran konten - Kerugian pelatihan dihitung hanya pada token keluaran akhir

Anda dapat menyertakan `reasoningContent` beberapa giliran asisten dalam percakapan multi-putaran.

Pedoman pemformatan

- Gunakan teks biasa untuk konten penalaran
- Hindari tag markup seperti `<thinking>` dan `</thinking>` kecuali secara khusus diperlukan oleh tugas Anda
- Pastikan konten penalaran jelas dan relevan dengan proses pemecahan masalah

Kapan mengaktifkan mode penalaran

Setel `reasoning_enabled: true` dalam konfigurasi latihan Anda saat:

- Data pelatihan Anda memiliki token penalaran
- Anda ingin model menghasilkan token pemikiran sebelum menghasilkan output akhir

- Anda membutuhkan peningkatan kinerja pada tugas penalaran yang kompleks

Melatih Nova pada dataset non-penalaran dengan `reasoning_enabled = true` diizinkan. Namun, melakukan hal itu dapat menyebabkan model kehilangan kemampuan penalarannya, karena Nova terutama belajar untuk menghasilkan respons yang disajikan dalam data tanpa menerapkan penalaran. Jika Anda ingin melatih Nova pada kumpulan data non-penalaran tetapi masih mengharapkan penalaran selama inferensi, Anda dapat menonaktifkan penalaran selama pelatihan (`reasoning_enabled = false`) tetapi mengaktifkannya untuk inferensi. Meskipun pendekatan ini memungkinkan penalaran digunakan pada waktu inferensi, pendekatan ini tidak menjamin peningkatan kinerja dibandingkan dengan inferensi tanpa penalaran. Secara umum, aktifkan penalaran untuk pelatihan dan inferensi saat menggunakan kumpulan data penalaran, dan nonaktifkan keduanya saat menggunakan kumpulan data non-penalaran.

Atur `reasoning_enabled: false` kapan:

- Data pelatihan Anda tidak memiliki token penalaran
- Anda melatih tugas-tugas langsung yang tidak mendapat manfaat dari langkah-langkah penalaran eksplisit
- Anda ingin mengoptimalkan kecepatan dan mengurangi penggunaan token

Menghasilkan data penalaran

Jika kumpulan data Anda tidak memiliki jejak penalaran, Anda dapat membuatnya menggunakan model berkemampuan penalaran seperti Nova Premier. Berikan pasangan input-output Anda ke model dan tangkap proses penalarannya untuk membangun kumpulan data yang diperbesar dengan alasan.

Menggunakan token penalaran untuk pelatihan

Ketika pelatihan dengan mode penalaran diaktifkan, model belajar untuk memisahkan penalaran internal dari jawaban akhir. Proses pelatihan:

- Mengatur data sebagai tiga kali lipat: masukan, penalaran, dan jawaban
- Mengoptimalkan menggunakan kerugian prediksi token berikutnya standar dari token penalaran dan jawaban
- Mendorong model untuk bernalar secara internal sebelum menghasilkan tanggapan

Konten penalaran yang efektif

Konten penalaran berkualitas tinggi harus mencakup:

- Pikiran dan analisis menengah
- Pengurangan logis dan langkah inferensi
- Step-by-step pendekatan pemecahan masalah
- Hubungan eksplisit antara langkah dan kesimpulan

Ini membantu model mengembangkan kemampuan untuk “berpikir sebelum menjawab.”

Pedoman persiapan kumpulan data

Ukuran dan kualitas

- Ukuran yang disarankan - 2.000-10.000 sampel
- Sampel minimum - 200
- Prioritas - Kualitas di atas kuantitas. Pastikan contoh akurat dan beranotasi dengan baik
- Penyelarasan aplikasi — Dataset harus mencerminkan kasus penggunaan produksi Anda

Keanekaragaman

Sertakan beragam contoh yang:

- Tutupi berbagai input yang diharapkan
- Mewakili tingkat kesulitan yang berbeda
- Sertakan kasus tepi dan variasi
- Cegah overfitting ke pola yang sempit

Pemformatan keluaran

Tentukan dengan jelas format output yang diinginkan dalam tanggapan asisten:

- Struktur JSON
- Tabel
- Format CSV
- Format khusus khusus untuk aplikasi Anda

Percakapan multi-giliran

Untuk kumpulan data multi-putaran, ingat:

- Kerugian dihitung hanya pada giliran asisten, bukan putaran pengguna
- Setiap respons asisten harus diformat dengan benar
- Pertahankan konsistensi di seluruh belokan percakapan

Daftar periksa kualitas

- Ukuran dataset yang memadai (sampel 2K-10K)
- Beragam contoh yang mencakup semua kasus penggunaan
- Pemformatan keluaran yang jelas dan konsisten
- Label dan anotasi yang akurat
- Perwakilan skenario produksi
- Bebas dari kontradiksi atau ambiguitas

Mengunggah data Anda

Kumpulan data harus diunggah ke bucket yang dapat diakses oleh SageMaker pekerjaan pelatihan. Untuk informasi tentang menyetel izin yang tepat, lihat [Prasyarat](#).

Memulai pekerjaan pelatihan

Memilih hyperparameters dan memperbarui resep

Pengaturan untuk Nova 2.0 sebagian besar sama dengan Nova 1.0. Setelah data input diunggah ke S3, gunakan resep dari [SageMaker HyperPod Resep](#) di bawah Fine tuning folder. Untuk Nova 2.0, berikut ini adalah beberapa hyperparameter kunci yang dapat Anda perbarui berdasarkan kasus penggunaan. Berikut ini adalah contoh resep Nova 2.0 SFT PEFT. Untuk URI image container, gunakan `708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-TJ-SFT-V2-latest` untuk menjalankan tugas fine-tuning SFT.

Silakan gunakan v2.254.1 SageMaker AI pySDK untuk kompatibilitas ketat dengan pelatihan Nova. Memutakhirkan SDK ke versi v3.0 akan menghasilkan perubahan yang melanggar. Support untuk v3 dari SageMaker AI pySDK akan segera hadir.

Masukan Sampel

```
!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:
```

```
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

```

Resepnya juga mengandung sebagian besar hiperparameter yang sama dengan Nova 1.0. Hiperparameter yang menonjol adalah:

- **max_steps**— Jumlah langkah yang Anda inginkan untuk menjalankan pekerjaan. Umumnya, untuk satu zaman (satu kali berjalan melalui seluruh kumpulan data Anda), jumlah langkah = jumlah sampel data/ukuran batch global. Semakin besar jumlah langkah dan semakin kecil ukuran batch global Anda, semakin lama pekerjaan yang dibutuhkan untuk dijalankan.
- **reasoning_enabled**— Mengontrol mode penalaran untuk dataset Anda. Opsi:
 - **true**: Mengaktifkan mode penalaran (setara dengan penalaran tinggi)
 - **false**: Menonaktifkan mode penalaran

Catatan: Untuk SFT, tidak ada kontrol granular atas tingkat upaya penalaran. Pengaturan **reasoning_enabled: true** memungkinkan kemampuan penalaran penuh.

- **peft.peft_scheme**— Mengatur ini ke "lora" memungkinkan penyetelan halus berbasis PEFT. Mengaturnya ke null (tanpa tanda kutip) memungkinkan penyetelan halus Peringkat Penuh.

Mulai pekerjaan pelatihan

```

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

Melewati kumpulan data validasi tidak didukung untuk fine tuning Nova 2.0 yang diawasi.

Untuk memulai pekerjaan:

- Perbarui resep dengan jalur dataset dan hyperparameters Anda

- Jalankan sel yang ditentukan di buku catatan untuk mengirimkan pekerjaan pelatihan

Notebook menangani pengiriman pekerjaan dan menyediakan pelacakan status.

Reinforcement Fine-Tuning (RFT) dengan model Amazon Nova

Ikhtisar

Apa itu RFT?

Reinforcement fine-tuning (RFT) meningkatkan kinerja model dengan melatih sinyal umpan balik — skor atau penghargaan yang dapat diukur yang menunjukkan seberapa baik kinerja model — daripada jawaban yang benar dan tepat. Tidak seperti fine-tuning yang diawasi yang belajar dari pasangan input-output, RFT menggunakan fungsi hadiah untuk mengevaluasi respons model dan secara iteratif mengoptimalkan model untuk memaksimalkan penghargaan ini. Pendekatan ini unggul ketika mendefinisikan output yang benar secara tepat menantang, tetapi Anda dapat mengukur kualitas respons dengan andal.

Kapan menggunakan RFT

Gunakan RFT ketika Anda dapat menentukan kriteria keberhasilan yang jelas dan terukur tetapi berjuang untuk memberikan output yang tepat untuk pelatihan. Ini ideal untuk:

- Tugas di mana kualitas bersifat subjektif atau beragam (penulisan kreatif, pengoptimalan kode, penalaran kompleks)
- Skenario dengan beberapa solusi valid di mana beberapa jelas lebih baik daripada yang lain
- Aplikasi yang membutuhkan perbaikan berulang, personalisasi, atau kepatuhan terhadap aturan bisnis yang kompleks
- Kasus di mana mengumpulkan contoh berlabel berkualitas tinggi mahal atau tidak praktis

Kasus penggunaan terbaik

RFT unggul dalam domain di mana kualitas output dapat diukur secara objektif tetapi respons optimal sulit untuk didefinisikan di muka:

- Pemecahan masalah matematika dan pembuatan kode
- Penalaran ilmiah dan analisis data terstruktur

- Tugas yang membutuhkan step-by-step penalaran atau pemecahan masalah multi-putaran
- Aplikasi menyeimbangkan berbagai tujuan (akurasi, efisiensi, gaya)
- Skenario di mana keberhasilan dapat diverifikasi secara terprogram melalui hasil eksekusi atau metrik kinerja

Model yang didukung

Nova Lite 2.0

Ikhtisar format data

[Data pelatihan RFT harus mengikuti format Fine-Tuning Penguatan OpenAI.](#) Setiap contoh pelatihan adalah objek JSON yang berisi:

- `messagesArray` dengan giliran percakapan menggunakan `system` dan peran `user`
- `reference_answer` Bidang yang berisi output yang diharapkan atau kriteria evaluasi untuk perhitungan hadiah

Keterbatasan saat ini

- Hanya teks

Contoh format data

Setiap contoh harus pada satu baris dalam file JSONL Anda, dengan satu objek JSON per baris.

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` Bidang berisi output yang diharapkan atau kriteria evaluasi yang digunakan fungsi hadiah Anda untuk menilai respons model. Ini tidak terbatas pada output terstruktur—dapat berisi format apa pun yang membantu fungsi hadiah Anda mengevaluasi kualitas.

Rekomendasi ukuran set data

Titik awal

- Minimal 100 contoh pelatihan
- Minimal 100 contoh evaluasi

Pendekatan evaluasi-pertama

Sebelum berinvestasi dalam pelatihan RFT skala besar, evaluasi kinerja dasar model Anda:

- Kinerja tinggi (hadiah > 95%) — RFT mungkin tidak perlu — model Anda sudah berkinerja baik

- Kinerja sangat buruk (hadiah 0%) - Beralih ke SFT terlebih dahulu untuk membangun kemampuan dasar
- Performa moderat — RFT kemungkinan tepat

Dimulai dengan kumpulan data kecil memungkinkan Anda untuk:

- Validasi fungsi reward Anda bebas bug
- Konfirmasikan RFT adalah pendekatan yang tepat untuk kasus penggunaan Anda
- Identifikasi dan perbaiki masalah lebih awal
- Uji alur kerja sebelum meningkatkan

Setelah divalidasi, Anda dapat memperluas ke kumpulan data yang lebih besar untuk lebih meningkatkan kinerja.

Karakteristik data pelatihan yang efektif

Kejelasan dan konsistensi

Contoh RFT yang baik membutuhkan data input yang jelas dan tidak ambigu yang memungkinkan perhitungan hadiah yang akurat di berbagai output model. Hindari kebisingan dalam data Anda, termasuk:

- Pemformatan yang tidak konsisten
- Label atau instruksi yang kontradiktif
- Petunjuk ambigu
- Jawaban referensi yang bertentangan

Ambiguitas apa pun akan menyesatkan proses pelatihan dan menyebabkan model mempelajari perilaku yang tidak diinginkan.

Keanekaragaman

Dataset Anda harus menangkap keragaman penuh kasus penggunaan produksi untuk memastikan kinerja dunia nyata yang kuat. Termasuk:

- Format input dan kasus tepi yang berbeda
- Memetakan pola penggunaan produksi aktual dari log dan analisis pengguna

- Sampel di seluruh jenis pengguna, wilayah geografis, dan variasi musiman
- Sertakan tingkat kesulitan dari masalah sederhana hingga yang kompleks

Pertimbangan fungsi penghargaan

Rancang fungsi hadiah Anda untuk pelatihan yang efisien:

- Jalankan dalam hitungan detik (bukan menit)
- Paralelisasi secara efektif dengan Lambda
- Kembalikan skor yang konsisten dan andal
- Tangani berbagai jenis keluaran model dengan anggun

Fungsi hadiah yang cepat dan dapat diskalakan memungkinkan iterasi cepat dan eksperimen hemat biaya.

Properti tambahan

Format data RFT mendukung bidang khusus di luar persyaratan skema inti (`messagesdanreference_answer`). Fleksibilitas ini memungkinkan Anda menambahkan data tambahan yang dibutuhkan fungsi hadiah Anda untuk evaluasi yang tepat.

Note

Anda tidak perlu mengonfigurasi ini dalam resep Anda—format data secara inheren mendukung bidang tambahan. Cukup sertakan mereka dalam data pelatihan Anda JSON, dan mereka akan diteruskan ke fungsi hadiah Anda di metadata lapangan.

Properti tambahan umum

Contoh bidang metadata:

- `task_id`— Pengidentifikasi unik untuk melacak
- `difficulty_level`— Indikator kompleksitas masalah
- `domain`— Bidang subjek atau kategori
- `expected_reasoning_steps`— Jumlah langkah dalam solusi

Contoh dengan properti tambahan

```
{
  "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
}
```

Bidang tambahan ini diteruskan ke fungsi hadiah Anda selama evaluasi, memungkinkan logika penilaian canggih yang disesuaikan dengan kasus penggunaan spesifik Anda.

Konfigurasi pelatihan

Resep sampel

```
# 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)

```

Pelatihan RFT menggunakan LLM sebagai juri

Ikhtisar

Model bahasa besar (LLMs) semakin banyak digunakan sebagai juri dalam alur kerja penyempurnaan penguatan (RFT), menyediakan sinyal hadiah otomatis yang memandu pengoptimalan model. Dalam pendekatan ini, LLM mengevaluasi keluaran model terhadap kriteria yang ditentukan—apakah menilai kebenaran, kualitas, kepatuhan gaya, atau kesetaraan semantik—dan memberikan penghargaan yang mendorong proses pembelajaran penguatan.

Ini sangat berharga untuk tugas-tugas di mana fungsi hadiah tradisional sulit untuk didefinisikan secara terprogram, seperti menentukan apakah representasi yang berbeda (seperti “1/3”, “0.333”, dan “sepertiga”) setara secara semantik, atau mengevaluasi kualitas bernuansa seperti koherensi dan relevansi. Dengan menggunakan juri berbasis LLM sebagai fungsi penghargaan, Anda dapat menskalakan RFT ke domain kompleks tanpa memerlukan anotasi manusia yang ekstensif, memungkinkan iterasi cepat dan peningkatan berkelanjutan model Anda di berbagai kasus penggunaan di luar masalah penyelarasan tradisional.

Pemilihan mode penalaran

Mode yang tersedia

- none - Tidak ada alasan (hilangkan bidang `reasing_effort`)
- rendah — Overhead penalaran minimal
- tinggi - Kemampuan penalaran maksimum (default saat `reasing_effort` ditentukan)

 Note

Tidak ada opsi media untuk RFT. Jika bidang `reasing_effort` tidak ada dalam konfigurasi Anda, penalaran akan dinonaktifkan. Saat penalaran diaktifkan, Anda harus mengatur `max_new_tokens` ke 32768 untuk mengakomodasi output penalaran yang diperluas.

Kapan menggunakan setiap mode

Gunakan penalaran tinggi untuk:

- Tugas analitis yang kompleks
- Pemecahan masalah matematika
- Pengurangan logis multi-langkah
- Tugas di mana step-by-step berpikir menambah nilai

Gunakan none (hilangkan `reasing_effort`) atau alasan rendah untuk:

- Pertanyaan faktual sederhana
- Klasifikasi langsung
- Optimalisasi kecepatan dan biaya
- Menjawab pertanyaan langsung

Pengorbanan biaya dan kinerja

Mode penalaran yang lebih tinggi meningkat:

- Waktu dan biaya pelatihan
- Latensi inferensi dan biaya
- Kemampuan model untuk tugas penalaran yang kompleks

Memvalidasi hakim LLM Anda

Sebelum menerapkan LLM-as-a-judge dalam produksi, validasi bahwa evaluasi model hakim selaras dengan penilaian manusia. Ini melibatkan:

- Mengukur tingkat kesepakatan antara hakim LLM dan evaluator manusia pada sampel yang representatif dari tugas Anda
- Memastikan bahwa perjanjian LLM dengan manusia memenuhi atau melampaui tingkat perjanjian antar manusia
- Mengidentifikasi bias potensial dalam model hakim
- Membangun kepercayaan bahwa sinyal hadiah memandu model Anda ke arah yang diinginkan

Langkah validasi ini membantu memastikan proses evaluasi otomatis akan menghasilkan model yang memenuhi kriteria kualitas produksi Anda.

Konfigurasi Lambda untuk hakim LLM

Menggunakan LLM sebagai juri adalah perpanjangan dari penggunaan fungsi Lambda untuk Pembelajaran Penguatan dengan Hadiah yang Dapat Diverifikasi (RLVR). Di dalam fungsi Lambda, Anda melakukan panggilan ke salah satu model yang dihosting di Amazon Bedrock.

Persyaratan konfigurasi penting:

Konfigurasi	Persyaratan	Detail
Throughput Amazon Bedrock	Kuota yang cukup	Pastikan kuota throughput Anda untuk model Amazon Bedrock yang digunakan cukup untuk beban kerja latihan Anda
Batas waktu Lambda	Batas waktu diperpanjang	Konfigurasikan batas waktu fungsi Lambda Anda hingga maksimum 15 menit. Pengaturan default adalah 3 detik, yang tidak cukup untuk respons model Amazon Bedrock
Konkurensi Lambda	Peningkatan konkurensi	Lambda dipanggil secara paralel selama pelatihan. Meningkatkan konkurensi untuk memaksimalkan throughput yang tersedia
Konfigurasi resep	Cocokkan pengaturan Lambda	Batas konkurensi harus dikonfigurasi dalam resep Anda

Menciptakan dan menjalankan pekerjaan

Memulai pekerjaan pelatihan

Gunakan templat buku catatan pekerjaan SageMaker pelatihan: <https://docs.aws.amazon.com/sagemaker/latest/dg/nova-fine-tuning-training-job.html#nova-model-training-jobs-notebook>

Persyaratan instans

Wadah mendukung pelatihan Peringkat Penuh dan LoRa:

- Pelatihan LoRa - 2/4/6/8 × p5.48xlarge atau instans p5en.48xlarge
- Pelatihan Peringkat Penuh - 2/4/6/8 × instans p5.48xlarge (wajib)

Pelatihan pemantauan

Log pelatihan mencakup metrik komprehensif di setiap langkah. Kategori metrik utama:

Metrik skor

- `critic/rewards/mean`, `critic/rewards/max`, `critic/rewards/min` — Distribusi hadiah
- `val-score/rewards/mean@1` — Hadiah validasi

Perilaku model

- `actor/entropy` — Variasi kebijakan (lebih tinggi = lebih eksplorasi)

Pelatihan kesehatan

- `actor/pg_loss` — Kehilangan gradien kebijakan
- `actor/pg_clipfrac` — Frekuensi pembaruan terpotong
- `actor/grad_norm` — Besaran gradien

Karakteristik respons

- `prompt_length/mean`, `prompt_length/max`, `prompt_length/min` — Masukan statistik token
- `response_length/mean`, `response_length/max`, `response_length/min` — Statistik token keluaran

- `response/aborted_ratio`— Tingkat generasi tidak lengkap (0 = semua selesai)

Performa

- `perf/throughput`— Throughput pelatihan
- `perf/time_per_step`— Waktu per langkah pelatihan
- `timing_per_token_ms/*`— Waktu pemrosesan per token

Penggunaan sumber daya

- `perf/max_memory_allocated_gb`, `perf/max_memory_reserved_gb` — Memori GPU
- `perf/cpu_memory_used_gb`— Memori CPU

Menggunakan model yang disetel dengan baik

Setelah pelatihan selesai, pos pemeriksaan model akhir disimpan ke lokasi keluaran yang Anda tentukan. Jalur pos pemeriksaan tersedia di:

- Log pelatihan
- `manifest.json` berkas di lokasi keluaran Amazon S3 (ditentukan oleh `output_s3_uri` di buku catatan Anda)

Keterbatasan dan praktik terbaik

Batasan

- Batas waktu Lambda - Fungsi hadiah harus selesai dalam waktu 15 menit (mencegah proses pelarian dan mengelola biaya)
- Hanya satu putaran - Percakapan multi-putaran tidak didukung
- Persyaratan data - Membutuhkan keragaman yang cukup; berjuang dengan imbalan yang jarang (< 5% contoh positif)
- Biaya komputasi — Lebih mahal daripada fine-tuning yang diawasi
- Tidak ada data multi-modal - Hanya tipe data teks yang didukung

Praktik terbaik

Mulai dari yang kecil

- Mulailah dengan 100-200 contoh
- Validasi kebenaran fungsi hadiah
- Skala secara bertahap berdasarkan hasil

Evaluasi pra-pelatihan

- Uji kinerja model dasar sebelum RFT
- Jika hadiah konsisten 0%, gunakan SFT terlebih dahulu untuk membangun kemampuan dasar
- Jika hadiah > 95%, RFT mungkin tidak diperlukan

Pantau pelatihan

- Lacak skor dan distribusi hadiah rata-rata
- Perhatikan overfitting (hadiah pelatihan meningkat sementara imbalan validasi berkurang)
- Cari pola yang menyangkut:
 - Hadiah yang berada di bawah 0,15
 - Meningkatkan varians hadiah dari waktu ke waktu
 - Menurunnya kinerja validasi

Optimalkan fungsi hadiah

- Jalankan dalam hitungan detik (bukan menit)
- Minimalkan panggilan API eksternal
- Gunakan algoritma yang efisien
- Menerapkan penanganan kesalahan yang tepat
- Manfaatkan penskalaan paralel Lambda

Strategi iterasi

Jika hadiah tidak membaik:

- Sesuaikan desain fungsi hadiah

- Meningkatkan keragaman dataset
- Tambahkan lebih banyak contoh yang representatif
- Verifikasi sinyal hadiah jelas dan konsisten

Kemampuan lanjutan: Nova Forge

Untuk pengguna yang membutuhkan kemampuan canggih di luar batasan RFT standar, Nova Forge tersedia sebagai penawaran layanan berlangganan berbayar:

- Dukungan percakapan multi-giliran
- Fungsi hadiah dengan > 15 menit waktu eksekusi
- Algoritma tambahan dan opsi penyetelan
- Modifikasi resep pelatihan khusus
- State-of-the-art Teknik AI

Nova Forge berjalan SageMaker HyperPod dan dirancang untuk mendukung pelanggan perusahaan untuk membangun model perbatasan mereka sendiri.

Perintah dan tips yang berguna

Kumpulan [skrip observabilitas](#) tersedia untuk membantu memantau status dan kemajuan pekerjaan pelatihan.

Skrip yang tersedia adalah:

- Mengaktifkan pemberitahuan email untuk pembaruan status pekerjaan pelatihan
- Memperoleh perkiraan waktu pelatihan berdasarkan konfigurasi pekerjaan
- Memperoleh perkiraan berapa lama pelatihan yang diharapkan untuk pekerjaan yang sedang berlangsung

Instalasi

Note

Pastikan untuk menyegarkan AWS kredensial Anda sebelum menggunakan salah satu skrip berikut.

```
pip install boto3
git clone https://github.com/aws-samples/amazon-nova-samples.git
cd amazon-nova-samples/customization/SageMakerUilts/SageMakerJobsMonitoring/
```

Penggunaan dasar

```
# 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
```

Silakan lihat [di sini](#) untuk detail dan contoh tambahan.

Memantau Kemajuan di Seluruh Iterasi



Anda dapat melacak metrik melalui MLflow.

Kustomisasi Nova - MLFlow pengaturan untuk SageMaker HyperPod

Untuk mengaktifkan SageMaker HyperPod lingkungan Anda menghasilkan metrik MLFlow, Anda perlu melakukan beberapa pengaturan tambahan.

1. Buka Amazon SageMaker AI
2. Pilih SageMaker Studio
 - a. Jika ada profil yang sudah dibuat, pilih “Open Studio”.
 - b. Jika tidak ada profil yang dibuat, pilih “Buat SageMaker Domain” untuk mengaturnya

3. Pilih MLFlow. Jika tidak ada MLFlow Aplikasi yang dibuat, pilih “Buat MLFlow Aplikasi”
4. Klik copy/paste tombol atau item menu “Lihat Detail” di Aplikasi Aliran MI untuk mendapatkan ARN. Anda akan membutuhkan ini ketika Anda mengirimkan pekerjaan pelatihan Anda.



5. Pada peran eksekusi HyperPod klaster, tambahkan kebijakan berikut. Ini akan memungkinkan HyperPod cluster memanggil MLFlow API untuk menerbitkan metrik.

```
{
  "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": "*"
    }
  ]
}
```

Mengirimkan pekerjaan melalui CLI

Tentukan 4 parameter override baru, baik di baris perintah, atau di resep yaml.

1. `mlflow_tracking_uri`: ARN dari Aplikasi MLFlow
2. `mlflow_experiment_name`: Nama untuk percobaan ini
3. `mlflow_experiment_name`: Nama eksperimen tempat metrik akan disimpan MLFlow
4. `mlflow_run_name`: Nama untuk percobaan ini

Baris perintah

```
--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"
```

Mengirimkan pekerjaan melalui UI Studio SageMaker

MLFlow integrasi sudah dibangun ke dalam pengalaman UI SageMaker Studio. Saat mengirimkan pekerjaan pelatihan, cukup tunjukkan instance MLFlow Aplikasi mana yang akan digunakan.

1. Di SageMaker Studio, navigasikan ke Models> Nova 2.0 Lite > Customize > Customize with UI.
2. Perluas bagian Konfigurasi Lanjutan
3. Pilih MLFlow Aplikasi tempat Anda ingin mengirim metrik pelatihan. Anda juga dapat mengatur nama eksperimen dan eksperimen yang dijalankan di sini.

The screenshot shows the MLflow console interface. At the top, it says 'MLflow'. Below that, there's a section 'MLflow Resource' with a message 'MLflow resource selected for experiment tracking.' and a dropdown menu showing 'DefaultMLFlowApp'. Under 'Experiment name', it says 'Default name applied. Enter a new name if desired.' and has a text input field containing 'myuser-sft-lora-exp1'. Under 'Experiment run', it says 'The run name is autogenerated by default. Specify a new name if desired.' and has a text input field containing 'myuser-sft-lora-exp1-1766499113356'.

Mengirimkan pekerjaan melalui AWS CLI

Jika Anda menggunakan AWS CLI, Anda harus membuat MLflow aplikasi dan meneruskannya sebagai masukan ke permintaan API pekerjaan pelatihan.

```
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)
```

Buat MLflow aplikasi

Menggunakan UI Studio: Jika Anda membuat pekerjaan pelatihan melalui UI Studio, MLflow aplikasi default dibuat secara otomatis dan dipilih secara default di bawah Opsi Lanjutan.

Menggunakan CLI: Jika Anda menggunakan CLI, Anda harus membuat MLflow aplikasi dan meneruskannya sebagai input ke permintaan API pekerjaan pelatihan.

```
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)
```

Akses MLflow aplikasinya

Menggunakan CLI: Buat URL yang telah ditandatangani sebelumnya untuk mengakses UI aplikasi: MLflow

```
aws sagemaker create-presigned-mlflow-app-url \
  --arn $mlflow_app_arn \
  --region $region \
  --output text
```

Menggunakan UI Studio: UI Studio menampilkan metrik kunci yang disimpan MLflow dan menyediakan tautan ke UI MLflow aplikasi.

Metrik kunci untuk dilacak

Pantau metrik ini di seluruh iterasi untuk menilai peningkatan dan melacak kemajuan pekerjaan:

Untuk SFT

- Kurva kehilangan pelatihan
- Jumlah sampel yang dikonsumsi dan waktu untuk memproses sampel
- Akurasi kinerja pada set uji yang diheld-out
- Kepatuhan format (misalnya, tingkat keluaran JSON yang valid)
- Kebingungan pada data evaluasi khusus domain

Untuk RFT

- Skor hadiah rata-rata selama pelatihan
- Distribusi hadiah (persentase respons hadiah tinggi)
- Tren hadiah validasi (perhatikan pemasangan yang berlebihan)
- Tingkat keberhasilan khusus tugas (misalnya, tingkat kelulusan eksekusi kode, akurasi masalah matematika)

Umum

- Delta kinerja benchmark antara iterasi
- Skor evaluasi manusia pada sampel yang representatif
- Metrik produksi (jika menerapkan secara berulang)

Menentukan kapan harus berhenti

Berhenti iterasi saat:

- Dataran tinggi kinerja: Pelatihan tambahan tidak lagi meningkatkan metrik target secara bermakna
- Peralihan teknik membantu: Jika satu teknik mencapai puncaknya, coba beralih (misalnya, SFT → RFT → SFT) untuk menerobos langit-langit kinerja
- Metrik target tercapai: Kriteria keberhasilan Anda terpenuhi
- Regresi terdeteksi: Iterasi baru menurunkan kinerja (lihat prosedur rollback di bawah)

Untuk prosedur evaluasi terperinci, lihat bagian Evaluasi.

Mengevaluasi model terlatih SageMaker AI Anda

Tujuan dari proses evaluasi adalah untuk menilai kinerja model terlatih terhadap tolok ukur atau kumpulan data khusus. Proses evaluasi biasanya melibatkan langkah-langkah untuk membuat resep evaluasi yang menunjuk ke model terlatih, menentukan kumpulan data dan metrik evaluasi, menyerahkan pekerjaan terpisah untuk evaluasi, dan mengevaluasi terhadap tolok ukur standar atau data khusus. Proses evaluasi akan menampilkan metrik kinerja yang disimpan di bucket Amazon S3 Anda.

Note

Proses evaluasi yang dijelaskan dalam topik ini adalah proses offline. Model ini diuji terhadap tolok ukur tetap dengan jawaban yang telah ditentukan, daripada dinilai secara real-time atau melalui interaksi pengguna langsung. [Untuk evaluasi waktu nyata, Anda dapat menguji model setelah diterapkan ke Amazon Bedrock dengan memanggil Amazon Bedrock Runtime. APIs](#)

Topik

- [Prasyarat](#)

- [Tugas benchmark yang tersedia](#)
- [Evaluasi konfigurasi spesifik](#)
- [Menjalankan pekerjaan pelatihan evaluasi](#)
- [Menilai dan menganalisis hasil evaluasi](#)
- [Evaluasi praktik terbaik dan pemecahan masalah](#)
- [Subtugas yang tersedia](#)
- [Evaluasi model penalaran](#)
- [Evaluasi RFT](#)
- [Menerapkan fungsi hadiah](#)

Prasyarat

Sebelum Anda memulai pekerjaan pelatihan evaluasi, perhatikan hal berikut.

- Model Amazon Nova SageMaker terlatih AI yang ingin Anda evaluasi kinerjanya.
- Resep dasar Amazon Nova untuk evaluasi. Untuk informasi selengkapnya, lihat [???](#).

Tugas benchmark yang tersedia

Paket kode sampel tersedia yang menunjukkan cara menghitung metrik tolok ukur menggunakan fitur evaluasi model SageMaker AI untuk Amazon Nova. Untuk mengakses paket kode, lihat [Sampel-Nova-lighteval-custom-task](#).

Berikut adalah daftar tolok ukur standar industri yang tersedia yang didukung. Anda dapat menentukan tolok ukur berikut dalam `eval_task` parameter.

Tolok ukur yang tersedia untuk evaluasi model

Tolok Ukur	Modalitas	Deskripsi	Metrik-metrik	Strategi	Subtugas tersedia
mmlu	Teks	Pemahaman Bahasa Multi-tugas - Menguji pengetahuan	ketepatan	zs_cot	Ya

Tolok Ukur	Modalitas	Deskripsi	Metrik-metrik	Strategi	Subtugas tersedia
		an di 57 mata pelajaran.			
mmlu_pro	Teks	MMLU - Subset Profesional - Berfokus pada domain profesional seperti hukum, kedokteran, akuntansi, dan teknik.	ketepatan	zs_cot	Tidak
bbh	Teks	Tugas Penalaran Lanjutan - Kumpulan masalah menantang yang menguji keterampilan kognitif dan pemecahan masalah tingkat tinggi.	ketepatan	fs_cot	Ya

Tolok Ukur	Modalitas	Deskripsi	Metrik-metrik	Strategi	Subtugas tersedia
gpqa	Teks	Penjawab Pertanyaan Fisika Umum — Menilai pemahaman konsep fisika dan kemampuan pemecahan masalah terkait.	ketepatan	zs_cot	Tidak
matematika	Teks	Pemecahan Masalah Matematika — Mengukur penalaran matematis di seluruh topik termasuk aljabar, kalkulus, dan masalah kata.	exact_match	zs_cot	Ya

Tolok Ukur	Modalitas	Deskripsi	Metrik-metrik	Strategi	Subtugas tersedia
strong_tolak	Teks	Quality-Control Task — Menguji kemampuan model untuk mendeteksi dan menolak konten yang tidak pantas, berbahaya, atau salah.	defleksi	zs	Ya
ifeval	Teks	Instruksi-Mengikuti Evaluasi - Mengukur seberapa akurat model mengikuti instruksi yang diberikan dan menyelesaikan tugas untuk spesifikasi.	ketepatan	zs	Tidak

Tolok Ukur	Modalitas	Deskripsi	Metrik-metrik	Strategi	Subtugas tersedia
gen_qa	Multi-Modal (gambar)	Evaluasi Dataset Kustom - Memungkinkan Anda menyediakan kumpulan data Anda sendiri untuk benchmarking, membandingkan output model dengan jawaban referensi dengan metrik seperti ROUGE dan BLEU. gen_qamenduk inferensi gambar untuk model berbasis Amazon Nova Lite atau Amazon Nova Pro. Juga mendukung Bring-Your-	all	gen_qa	Tidak

Tolok Ukur	Modalitas	Deskripsi	Metrik-metrik	Strategi	Subtugas tersedia
		Own Metrik lambda. (Untuk evaluasi RFT, silakan gunakan resep eval RFT)			
mmmu	Multi-Modal	Pemahaman Multimodal I Multidisiplin Besar (MMMU) - Tolok ukur tingkat perguruan tinggi yang terdiri dari pertanyaan pilihan ganda dan terbuka dari 30 disiplin ilmu.)	ketepatan	zs_cot	Ya

Tolok Ukur	Modalitas	Deskripsi	Metrik-metrik	Strategi	Subtugas tersedia
llm_hakim	Teks	LLM-as-a-Judge Perbandingan Preferensi — Menggunakan model Nova Judge untuk menentukan preferensi antara respons berpasangan (B dibandingkan dengan A) untuk petunjuk Anda, menghitung probabilitas B lebih disukai daripada A.	all	hakim	Tidak

Tolok Ukur	Modalitas	Deskripsi	Metrik-metrik	Strategi	Subtugas tersedia
mm_llm_hakim	Multi-Modal (gambar)	Tolok ukur baru ini berperilaku sama dengan berbasis teks llm_judge di atas. Satu-satunya perbedaan adalah mendukung inferensi gambar.	all	hakim	Tidak

Tolok Ukur	Modalitas	Deskripsi	Metrik-metrik	Strategi	Subtugas tersedia
rubric_llm_judge	Teks	Rubric Judge adalah model LLM-as-a-judge evaluasi yang disempurnakan yang dibangun di atas Nova 2.0 Lite. Berbeda dengan model hakim asli yang hanya memberikan putusan preferensi, Rubric Judge secara dinamis menghasilkan kriteria evaluasi khusus yang disesuaikan dengan setiap prompt dan memberikan skor granular di berbagai dimensi.	all	hakim	Tidak

Tolok Ukur	Modalitas	Deskripsi	Metrik-metrik	Strategi	Subtugas tersedia
aime_2024	Teks	AIME 2024 - Ujian Matematik a Undangan Amerika menguji penalaran matematik a tingkat lanjut dan pemecahan masalah	exact_match	zs_cot	Tidak
calendar_ scheduling	Teks	Rencana Alami - Kalender Penjadwal an tugas menguji kemampuan perencana an untuk menjadwal kan rapat di beberapa hari dan orang	exact_match	fs	Tidak

Tolok Ukur	Modalitas	Deskripsi	Metrik-metrik	Strategi	Subtugas tersedia
kemanusiaan	Teks	HumanEval - Dataset benchmark yang dirancang untuk mengevaluasi kemampuan pembuatan kode model bahasa besar	lulus @1	zs	Tidak

Evaluasi konfigurasi spesifik

Di bawah ini adalah rincian komponen kunci dalam resep dan panduan tentang cara memodifikasinya untuk kasus penggunaan Anda.

Memahami dan memodifikasi resep Anda

Konfigurasi run umum

```
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:** Nama deskriptif untuk pekerjaan evaluasi Anda.
- **model_type:** Menentukan varian model Nova untuk digunakan. Jangan memodifikasi bidang ini secara manual. Opsinya meliputi:
 - Amazon. nova-micro-v1:0:128 k

- Amazon. nova-lite-v1:0:300 k
- Amazon. nova-pro-v1:0:300 k
- amazon.nova-2-lite-v 1:0:256 k
- `model_name_or_path`: Jalur ke model dasar atau jalur s3 untuk pos pemeriksaan pasca terlatih. Opsinya meliputi:
 - nova-mikro/prod
 - nova-lite/prod
 - nova-pro/prod
 - nova-lite-2/prod
- Jalur S3 untuk jalur pos pemeriksaan pasca terlatih () `s3:customer-escrow-111122223333-smtj-<unique_id>/<training_run_name>`

 Note

Evaluasi model pasca-terlatih

Untuk mengevaluasi model pasca-pelatihan setelah pekerjaan pelatihan Nova SFT, ikuti langkah-langkah ini setelah menjalankan pekerjaan pelatihan yang sukses. Di akhir log pelatihan, Anda akan melihat pesan log “Pelatihan selesai”. Anda juga akan menemukan `manifest.json` file di bucket keluaran Anda yang berisi lokasi pos pemeriksaan Anda. File ini akan berada di dalam `output.tar.gz` file di lokasi output S3 Anda. Untuk melanjutkan evaluasi, gunakan pos pemeriksaan ini dengan menyetelnya sebagai nilai untuk `run.model_name_or_path` konfigurasi resep Anda.

- `replica`: Jumlah instance komputasi yang akan digunakan untuk inferensi terdistribusi (menjalankan inferensi di beberapa node). Setel `replica > 1` untuk mengaktifkan inferensi multi-node, yang mempercepat evaluasi. Jika keduanya `instance_count` dan `replica` ditentukan, `instance_count` diutamakan. Perhatikan bahwa beberapa replika hanya berlaku untuk pekerjaan pelatihan SageMaker AI, bukan.
- `data_s3_path`: Jalur dataset masukan Amazon S3. Bidang ini diperlukan tetapi harus selalu dibiarkan kosong.
- `mlflow_tracking_uri`: (Opsional) Lokasi server MLflow pelacak (hanya diperlukan di SMHP)
- `mlflow_experiment_name`: (Opsional) Nama percobaan untuk mengelompokkan ML terkait berjalan bersama

- `mlflow_run_name`: (Opsional) Nama khusus untuk pelatihan tertentu yang dijalankan dalam eksperimen

Konfigurasi evaluasi

```
evaluation:
  task: mmlu
  strategy: zs_cot
  subtask: abstract_algebra
  metric: accuracy
```

- `task`: Menentukan benchmark evaluasi atau tugas untuk digunakan. Tugas yang didukung meliputi:
 - `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`: Mendefinisikan pendekatan evaluasi.
 - `zs_cot`: Zero-shot Chain of Thought - pendekatan untuk mendorong model bahasa besar yang mendorong step-by-step penalaran tanpa memerlukan contoh eksplisit.
 - `fs_cot`: Few-shot Chain of Thought - pendekatan yang memberikan beberapa contoh step-by-step penalaran sebelum meminta model untuk memecahkan masalah baru.

- `zs`: Zero-shot - pendekatan untuk memecahkan masalah tanpa contoh pelatihan sebelumnya.
- `gen_qa`: Strategi khusus untuk membawa dataset Anda sendiri.
- `judge`: Strategi khusus untuk Nova LLM sebagai Hakim dan `mm_llm_judge`.
- `subtask`: Opsional. Komponen spesifik dari tugas evaluasi. Untuk daftar lengkap subtugas yang tersedia, lihat [????](#).
- Periksa subtugas yang didukung dalam tugas benchmark yang tersedia.
- Harus menghapus bidang ini jika tidak ada tolok ukur subtugas.
- `metric`: Metrik evaluasi yang akan digunakan.
 - `accuracy`: Persentase jawaban yang benar.
 - `exact_match`: Untuk tolok ukur matematika, mengembalikan tingkat di mana string yang diprediksi input sama persis dengan referensi mereka.
 - `deflection`: Untuk tolok ukur penolakan yang kuat, kembalikan defleksi relatif ke model dasar dan metrik signifikansi perbedaan.
 - `all`:

Untuk `gen_qa`, bawa benchmark dataset Anda sendiri, kembalikan metrik berikut:

- `rouge1`: Mengukur tumpang tindih unigram (kata tunggal) antara teks yang dihasilkan dan referensi.
- `rouge2`: Mengukur tumpang tindih bigram (dua kata berturut-turut) antara teks yang dihasilkan dan referensi.
- `rougeL`: Mengukur urutan umum terpanjang antara teks, memungkinkan celah dalam pencocokan.
- `exact_match`: Skor biner (0 atau 1) menunjukkan apakah teks yang dihasilkan cocok dengan teks referensi persis, karakter demi karakter.
- `quasi_exact_match`: Mirip dengan kecocokan persis tetapi lebih lunak, biasanya mengabaikan kasus, tanda baca, dan perbedaan ruang putih.
- `f1_score`: Rata-rata harmonik presisi dan ingatan, mengukur tumpang tindih kata antara jawaban yang diprediksi dan referensi.
- `f1_score_quasi`: Mirip dengan `f1_score` tetapi dengan pencocokan yang lebih lunak, menggunakan perbandingan teks yang dinormalisasi yang mengabaikan perbedaan kecil.
- `bleu`: Mengukur presisi kecocokan n-gram antara teks yang dihasilkan dan referensi, yang biasa digunakan dalam evaluasi terjemahan.

Untuk `llm_judge` dan `mm_llm_judge`, bawa benchmark dataset Anda sendiri, kembalikan metrik berikut:

- `a_scores`: Jumlah kemenangan untuk `response_A` lintasan evaluasi maju dan mundur.
- `a_scores_stderr`: Kesalahan standar `response_A_scores` lintas penilaian berpasangan.
- `b_scores`: Mengukur Jumlah kemenangan untuk `response_B` lintasan evaluasi maju dan mundur.
- `a_scores_stderr`: Kesalahan standar `response_B_scores` lintas penilaian berpasangan.
- `ties`: Jumlah penilaian di mana `response_A` dan `response_B` dievaluasi sebagai sama.
- `ties_stderr`: Kesalahan standar `ties` lintas penilaian berpasangan.
- `inference_error`: Hitungan penilaian yang tidak dapat dievaluasi dengan benar.
- `score`: Skor agregat berdasarkan kemenangan dari umpan maju dan mundur untuk `response_B`
- `score_stderr`: Skor agregat berdasarkan kemenangan dari umpan maju dan mundur untuk `response_B`
- `inference_error_stderr`: Kesalahan standar skor agregat di seluruh penilaian berpasangan.
- `winrate` Probabilitas yang `response_B` akan lebih disukai daripada `response_A` dihitung menggunakan probabilitas Bradley-Terry.
- `lower_rate`: Batas bawah (persentil 2,5) dari perkiraan tingkat kemenangan dari pengambilan sampel bootstrap.
- `upper_rate`: Batas atas (persentil 97,5) dari perkiraan tingkat kemenangan dari pengambilan sampel bootstrap.

Konfigurasi inferensi (opsional)

```
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`: Jumlah maksimum token yang akan dihasilkan. Harus berupa bilangan bulat. (Tidak tersedia untuk Hakim LLM)
- `top_k`: Jumlah token probabilitas tertinggi untuk dipertimbangkan. Harus berupa bilangan bulat.
- `top_p`: Ambang probabilitas kumulatif untuk pengambilan sampel token. Harus berupa float antara 1,0 hingga 0,0.
- `temperature`: Keacakan dalam pemilihan token (lebih tinggi = lebih acak), pertahankan 0 untuk membuat hasilnya deterministik. Tipe float, nilai minimal adalah 0.
- `top_logprobs`: Jumlah logprob teratas yang akan dikembalikan dalam respons inferensi. Nilai ini harus berupa bilangan bulat dari 0 hingga 20. Logprobs berisi token keluaran yang dipertimbangkan dan probabilitas log dari setiap token keluaran yang dikembalikan dalam konten pesan.
- `reasoning_effort`: mengontrol perilaku penalaran untuk model yang mampu beralasan. Set `reasoning_effort` hanya ketika `model_type` menentukan model berkemampuan penalaran (saat ini). `amazon.nova-2-lite-v1:0:256k` Opsi yang tersedia adalah null (nilai default jika tidak disetel; menonaktifkan penalaran), rendah, atau tinggi.

Format Keluaran Probabilitas Log

Ketika `top_logprobs` dikonfigurasi dalam pengaturan inferensi Anda, output evaluasi mencakup probabilitas log tingkat token dalam file parquet. Setiap posisi token berisi kamus token kandidat teratas dengan probabilitas log mereka dalam struktur berikut:

```
{
  "Ġint": {"logprob_value": -17.8125, "decoded_value": " int"},
  "Ġthe": {"logprob_value": -2.345, "decoded_value": " the"}
}
```

Setiap entri token berisi:

- `logprob_value`: Nilai probabilitas log untuk token
- `decoded_value`: Representasi string decoded yang dapat dibaca manusia dari token

Token tokenizer mentah digunakan sebagai kunci kamus untuk memastikan keunikan, sekaligus `decoded_value` memberikan interpretasi yang dapat dibaca.

Contoh resep evaluasi

Amazon Nova menyediakan empat jenis resep evaluasi yang berbeda. Semua resep tersedia di [GitHub repositori SageMaker HyperPod resep](#).

Resep tolok ukur teks umum

Resep-resep ini memungkinkan Anda untuk mengevaluasi kemampuan dasar model Amazon Nova di seluruh rangkaian tolok ukur khusus teks yang komprehensif.

Format resep: `xxx_general_text_benchmark_eval.yaml`.

Bawa resep benchmark dataset Anda sendiri

Resep-resep ini memungkinkan Anda untuk membawa dataset Anda sendiri untuk benchmarking dan membandingkan output model untuk referensi jawaban menggunakan berbagai jenis metrik.

Format resep: `xxx_bring_your_own_dataset_eval.yaml`.

Bawa persyaratan dataset Anda sendiri

Format berkas:

- `gen_qa.jsonl` File tunggal yang berisi contoh evaluasi. Nama file harus tepat `gen_qa.jsonl`.
- Anda harus mengunggah kumpulan data Anda ke lokasi S3 tempat pekerjaan pelatihan SageMaker AI dapat diakses.
- File harus mengikuti format skema yang diperlukan untuk kumpulan data Tanya Jawab umum.

Persyaratan format skema - Setiap baris dalam `.jsonl` file harus berupa objek JSON dengan bidang berikut.

- Bidang yang diperlukan.

`query`: String yang berisi pertanyaan atau instruksi yang membutuhkan jawaban.

`response`: String yang berisi output model yang diharapkan.

- Bidang opsional.

`systemString` yang berisi prompt sistem yang mengatur perilaku, peran, atau kepribadian model AI sebelum memproses kueri.

`images`: Array berisi daftar objek dengan atribut data (string gambar yang dikodekan Base64).

metadata: String yang berisi metadata yang terkait dengan entri untuk tujuan penandaan.

Entri contoh

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

Untuk menggunakan kumpulan data kustom Anda, ubah resep evaluasi Anda dengan menambahkan bidang wajib berikut tanpa mengubah konfigurasi yang ada:

```
evaluation:
  task: gen_qa
  strategy: gen_qa
  metric: all
```

Batasan

- Hanya satu `.jsonl` file yang diizinkan per evaluasi.

- File harus benar-benar mengikuti skema yang ditentukan.

Bawa metrik Anda sendiri

Anda dapat membawa metrik Anda sendiri untuk sepenuhnya menyesuaikan alur kerja evaluasi model Anda dengan kemampuan pra-pemrosesan, pasca-pemrosesan, dan metrik khusus. Preprocessing memungkinkan Anda untuk memproses data input sebelum mengirimnya ke server inferensi, dan postprocessing memungkinkan Anda untuk menyesuaikan perhitungan metrik dan mengembalikan metrik kustom berdasarkan kebutuhan Anda.

Ikuti langkah-langkah ini untuk membawa metrik Anda sendiri dengan SDK evaluasi khusus.

1. Jika Anda belum melakukannya, [buat AWS Lambda fungsi](#) di tempat Akun AWS pertama Anda.
2. Unduh nova-custom-eval-layer.zip file pra-bangun dari [GitHub repositori](#). Anda dapat menggunakan SDK evaluasi kustom Nova open-source ini untuk memvalidasi muatan input dan output untuk fungsi kustom Anda dan menyediakan antarmuka terpadu untuk diintegrasikan dengan Nova membawa evaluasi metrik Anda sendiri selama pelatihan.
3. Unggah layer Lambda kustom menggunakan perintah berikut:

```
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. Tambahkan layer ini sebagai layer kustom ke fungsi Lambda Anda, bersama dengan AWS layer yang diperlukan: AWSLambdaPowertoolsPythonV3-python312-arm64 (diperlukan untuk pydantic ketergantungan).
5. Perbarui kode Lambda Anda menggunakan contoh yang disediakan, modifikasi kode sesuai kebutuhan. Kode contoh ini membuat fungsi Lambda untuk evaluasi kustom Nova dengan langkah-langkah preprocessing dan postprocessing untuk evaluasi model.

```
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. Berikan Lambda akses ke pekerjaan evaluasi. Pastikan peran eksekusi yang ditentukan untuk pekerjaan evaluasi mencakup kebijakan pemanggilan fungsi Lambda Anda. Berikut adalah contoh kebijakan.

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. Tinjau skema payload Lambda. Tabel berikut mencantumkan permintaan Lambda dan skema respons. Anda dapat memvalidasi skema Anda menggunakan SDK evaluasi kustom Nova.

	Lambda Permintaan Muatan	Muatan Respons Lambda
Prepros or	<pre>{ "process_type": "preproce ss",</pre>	<pre>{ "statusCode": 200, "body": {</pre>

	Lambda Permintaan Muatan	Muatan Respons Lambda
	<pre> "data": { "system": "You are a helpful assistant", "prompt": "What is 2+2?", "gold": "4" } } </pre>	<pre> "system": "You are a helpful assistant that can substitute * for addition", "prompt": "What is 2*2?", "gold": "4" } } </pre>
Postpro sor	<pre> { "process_type": "postproc ess", "data": { "prompt": "What is 2+2?", "inference_output": "2+2=4", "gold": "4" } } </pre>	<pre> { "statusCode": 200, "body": [{"metric": "accuracy", "value": 1.0}, {"metric": "f1_score", "value": 1.0}, {"metric": "exact_match", "value": 1}, {"metric": "length_ratio", "value": 0.8}] } </pre>

8. Ubah file resep. Inilah contohnya.

```

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`: Nama Sumber Daya Amazon (ARN) untuk fungsi Lambda Anda yang menangani preprocessing dan postprocessing.
- `lambda_type`: "custom_metrics" atau "rft".
- `preprocessing`: Apakah akan mengaktifkan operasi pra-pemrosesan khusus.

- `postprocessing`: Apakah akan mengaktifkan operasi pasca-pemrosesan khusus.
- `aggregation`: Fungsi agregasi bawaan (opsi yang valid: min, maks, rata-rata, jumlah).

Batasan

- Bawa metrik Anda sendiri hanya berlaku untuk kumpulan data input teks.
- Kumpulan data masukan multi-modal tidak didukung.
- Langkah preprocessing tidak memproses bidang metadata.

Nova LLM sebagai resep tolok ukur Hakim

Nova LLM Judge adalah fitur evaluasi model yang memungkinkan Anda membandingkan kualitas respons dari satu model dengan respons model dasar menggunakan kumpulan data khusus. [Ini menerima kumpulan data yang berisi petunjuk, respons dasar, dan respons penantang, kemudian menggunakan model Nova Judge untuk memberikan metrik tingkat kemenangan berdasarkan probabilitas Bradley-Terry melalui perbandingan berpasangan.](#) Format resep: `xxx_llm_judge_eval.yaml`.

Persyaratan set data Nova LLM

Format berkas:

- `llm_judge.jsonl` File tunggal yang berisi contoh evaluasi. Nama file harus tepat `llm_judge.jsonl`.
- Anda harus mengunggah kumpulan data Anda ke lokasi S3 tempat pekerjaan pelatihan SageMaker AI dapat diakses.
- File harus mengikuti format skema yang diperlukan untuk `llm_judge` kumpulan data.
- Dataset input harus memastikan semua catatan berada di bawah panjang konteks 12 k.

Format skema - Setiap baris dalam `.jsonl` file harus objek JSON dengan bidang berikut.

- Bidang yang diperlukan.

`prompt`: String yang berisi prompt untuk respons yang dihasilkan.

`response_A`: String yang berisi respons dasar.

`response_B`: String yang berisi respons alternatif dibandingkan dengan respons dasar.

Entri contoh

```
{
  "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."
}
```

Untuk menggunakan kumpulan data kustom Anda, ubah resep evaluasi Anda dengan bidang wajib berikut, jangan ubah konten apa pun:

```
evaluation:
  task: llm_judge
  strategy: judge
  metric: all
```

Batasan

- Hanya satu `.jsonl` file yang diizinkan per evaluasi.
- File harus benar-benar mengikuti skema yang ditentukan.
- Model Nova Judge sama di seluruh spesifikasi mikro/lite/pro.
- Model juri khusus saat ini tidak didukung.

Nova LLM sebagai Hakim untuk resep benchmark multi-modal (gambar)

Nova LLM Judge for multi-modal (image), kependekan dari Nova MM_LLM Judge, adalah fitur evaluasi model yang memungkinkan Anda membandingkan kualitas respons dari satu model dengan respons model dasar menggunakan kumpulan data khusus. [Ini menerima kumpulan data yang berisi petunjuk, respons dasar, dan respons penantang, dan gambar dalam bentuk string yang dikodekan Base64, kemudian menggunakan model Nova Judge untuk memberikan metrik tingkat kemenangan berdasarkan probabilitas Bradley-Terry melalui perbandingan berpasangan.](#) Format resep: `xxx_mm_llm_judge_eval.yaml`.

Persyaratan set data Nova LLM

Format berkas:

- `mm_llm_judge.jsonl` File tunggal yang berisi contoh evaluasi. Nama file harus `persis_llm_judge.jsonl`.
- Anda harus mengunggah kumpulan data Anda ke lokasi S3 tempat pekerjaan pelatihan SageMaker AI dapat mengaksesnya.
- File harus mengikuti format skema yang diperlukan untuk `mm_llm_judge` kumpulan data.
- Dataset input harus memastikan semua catatan berada di bawah panjang konteks 12 k, tidak termasuk atribut gambar.

Format skema - Setiap baris dalam `.jsonl` file harus objek JSON dengan bidang berikut.

- Bidang yang diperlukan.

`prompt`: String yang berisi prompt untuk respons yang dihasilkan.

`images`: Array yang berisi daftar objek dengan atribut data (nilainya adalah string gambar yang dikodekan Base64).

`response_A`: String yang berisi respons dasar.

`response_B`: String yang berisi respons alternatif dibandingkan dengan respons dasar.

Entri contoh

Untuk keterbacaan, contoh berikut mencakup baris dan lekukan baru, tetapi dalam kumpulan data yang sebenarnya, setiap catatan harus berada pada satu baris.

```
{
  "prompt": "What is in the image?",
  "images": [
    {
      "data": "data:image/jpeg;base64,/9j/2wBDAAQDAwQDAwQEAwQFBAQFBgo..."
    }
  ],
  "response_A": "a dog.",
  "response_B": "a cat.",
}
{
  "prompt": "How many animals are in each of the images?",
  "images": [
    {
      "data": "data:image/jpeg;base64,/9j/2wBDAAQDAwQDAwQEAwQFBAQFBgo..."
    },
    {
      "data": "data:image/jpeg;base64,/DKEafe3gihn..."
    }
  ],
  "response_A": "The first image contains one cat and the second image contains one dog",
  "response_B": "The first image has one animal and the second has one animal"
}
```

Untuk menggunakan kumpulan data kustom Anda, ubah resep evaluasi Anda dengan bidang wajib berikut, jangan ubah konten apa pun:

```
evaluation:
  task: mm_llm_judge
  strategy: judge
  metric: all
```

Batasan

- Hanya satu `.jsonl` file yang diizinkan per evaluasi.
- File harus benar-benar mengikuti skema yang ditentukan.
- Model Nova MM Judge hanya mendukung referensi gambar.
- Model Nova MM Judge sama di seluruh spesifikasi Amazon Nova Micro, Amazon Nova Lite, dan Amazon Nova Pro.
- Model juri khusus saat ini tidak didukung.
- URI gambar Amazon S3 tidak didukung.
- Dataset input harus memastikan semua catatan berada di bawah panjang konteks 12 k, tidak termasuk atribut gambar.

Mengevaluasi Pos Pemeriksaan CPT (Pra-Pelatihan Berkelanjutan)

Evaluasi model CPT (terus menerus pra-terlatih) dapat menjadi tantangan daripada model yang telah mengalami SFT (penyetelan halus yang diawasi) karena model CPT secara teratur tidak memiliki kemampuan untuk mengikuti instruksi. Alih-alih mengikuti instruksi, model CPT akan beroperasi sebagai model penyelesaian, yang berarti mereka hanya akan mencoba untuk melanjutkan pola yang disediakan dengan urutan token input. Mengingat keterbatasan ini, kumpulan data evaluasi tipikal mungkin tidak berfungsi dengan benar karena format input “Tanya Jawab” — alih-alih menjawab pertanyaan, model hanya akan mencoba melanjutkan pertanyaan yang sama. Namun, dengan memformat kumpulan data dengan cara tertentu untuk meminta model dalam gaya penyelesaian, kita bisa mendapatkan pemahaman tentang bagaimana kinerja model.

Ikuti langkah-langkah di bawah ini untuk memahami cara melakukan evaluasi pada model pra-pelatihan berkelanjutan menggunakan alur kerja evaluasi Nova Forge.

Persiapan dan Pemformatan Dataset

Mengevaluasi model CPT memanfaatkan alur kerja [Bring Your Own Dataset](#) yang sudah ada yang sudah disediakan dalam pengalaman evaluasi model Nova Forge. Namun, kueri dalam kumpulan data harus diformat dalam format “penyelesaian” murni karena model CPT tidak akan menanggapi permintaan gaya pertanyaan standar dengan cara yang sama seperti model SFT.

Keterbatasan penting lainnya dari model yang telah mengalami CPT semata-mata adalah ketidakmampuan mereka untuk menghasilkan STOP atau akhir token urutan — ini berarti bahwa model akan terus menghasilkan token sampai dihentikan secara paksa (seperti dengan parameter `max_new_tokens`). Mengingat keterbatasan ini, praktik terbaik adalah mengevaluasi model

menggunakan respons token tunggal (seperti pilihan ganda) untuk memastikan model tidak terus menghasilkan keluaran sampah yang tidak diperlukan setelah diminta.

Misalnya, kumpulan data evaluasi tipikal (seperti MMLU, GPQA, MATH, dll), mungkin meminta model dengan pertanyaan seperti:

```
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.)
```

Namun, model CPT tidak akan mengerti bagaimana menanggapi pertanyaan ini dengan benar karena kurangnya fine tuning pada instruksi berikut. Oleh karena itu, model CPT harus diminta dalam gaya penyelesaian, seperti:

```
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.)
```

Setelah pemeriksaan inferensi, logprobs keluaran yang dihasilkan oleh model akan memberikan rincian apakah model memproses input dengan benar dan menghasilkan respons yang benar. Tidak dijamin bahwa model akan selalu menghasilkan respons yang tepat (dalam hal ini, huruf D) yang diharapkan, namun, itu harus ada dalam logprobs jika model berfungsi dengan benar.

Contoh prompt gaya penyelesaian non-pilihan ganda lainnya:

```
The capital of France is
```

```
(Expected answer of Paris)
```

Kami mengharapkan model untuk menghasilkan respons “Paris” atau melihat token yang sesuai dengan “Paris” di suatu tempat dalam output logprobs.

Pemformatan Dataset

Evaluasi CPT memanfaatkan alur kerja [Bring Your Own Dataset](#) yang ada. Data harus diformat dalam format “respons kueri” dalam file JSONL yang dipisahkan oleh baris baru.

Contoh dataset dengan 4 entri di dalamnya:

```
{"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"}
```

Setiap baris harus berisi:

- query: Teks prompt untuk penyelesaian
- response: Penyelesaian yang diharapkan (kebenaran dasar)

Model akan menerima input teks mentah tanpa pemformatan obrolan. Model CPT biasanya belum dilatih pada token khusus dan tidak akan merespons templat obrolan dengan benar, jadi saat meminta model HANYA string yang disediakan dalam kueri akan dikirim ke model (dengan [BOS] token tambahan ditambahkan secara otomatis.)

Konfigurasi Resep

Berikut adalah contoh resep yang dikonfigurasi untuk mengevaluasi model CPT:

```
run:
  name: cpt_eval_job
  model_type: amazon.nova-2-lite-v1:0:256k
  model_name_or_path: s3://bucket/path/to/cpt-checkpoint/

evaluation:
  task: gen_qa # Required for CPT - bring your own dataset
  strategy: gen_qa
  metric: all # Returns rouge1, rouge2, rougeL, exact_match, f1_score, bleu
```

```
inference:
  checkpoint_is_instruction_tuned: "false" # Required for CPT checkpoints
  top_logprobs: 5 # Change to desired amount of logprobs to calculate
  max_new_tokens: 1 # Keep low for completion tasks
  temperature: 0.0
```

Perubahan utama untuk evaluasi CPT:

- `checkpoint_is_instruction_tuned: "false"`

Ini adalah parameter baru yang ditambahkan secara khusus untuk mendukung evaluasi berjalan di pos pemeriksaan CPT. Menyetel `checkpoint_is_instruction_tuned` ke `false` akan menonaktifkan template obrolan Amazon Nova default yang biasanya membungkus prompt input.

- `top_logprobs: 5`

Probabilitas log (logprobs) mengungkapkan distribusi kepercayaan model di seluruh kemungkinan token berikutnya, membantu Anda menilai apakah model telah mempelajari penyelesaian yang diharapkan selama pra-pelatihan. Biasanya, jika model berkinerja sebagaimana dimaksud, kita akan melihat respons yang diharapkan (yaitu, "A", "B", dll) sebagai token keluaran yang dihasilkan atau token di logprobs.

- `max_new_tokens: 1`

Model CPT biasanya belum dilatih untuk menghasilkan token "stop" atau "end of sequence" khusus yang belum memberi sinyal kapan harus menghentikan inferensi. Ini berarti model biasanya akan terus menghasilkan token baru sampai panjang token maks tertentu tercapai sehingga menghasilkan inferensi yang tidak perlu. Biasanya membatasi `max_new_tokens` ke 1 dan memberikan prompt yang dapat mengevaluasi model pada satu respons (seperti pertanyaan pilihan ganda) adalah cara paling efisien untuk meminta model. Menyetel `max_new_tokens` ke 1 memastikan bahwa token sampah tambahan tidak dihasilkan.

Parameter Kunci

- `checkpoint_is_instruction_tuned`: Harus disetel ke (atau sebagai boolean) untuk menonaktifkan templat obrolan `"false"` `false`
- `top_logprobs`: 5, direkomendasikan untuk melihat bagaimana model belajar selama CPT
- tugas: Harus `gen_qa` - Model CPT tidak dapat menggunakan tolok ukur mengikuti instruksi seperti MMLU atau MATH
- Strategi: Harus `gen_qa`

- `max_new_tokens`: Direkomendasikan untuk tetap rendah (1-5) karena model CPT melakukan penyelesaian, bukan pembuatan

Menjalankan pekerjaan pelatihan evaluasi

Mulai pekerjaan pelatihan menggunakan contoh notebook berikut. Silakan lihat buku catatan di bawah ini sebagai contoh untuk menjalankan pekerjaan pelatihan evaluasi. Untuk informasi selengkapnya, lihat [Menggunakan estimator SageMaker AI untuk menjalankan pekerjaan pelatihan](#).

Tabel referensi

Sebelum menjalankan buku catatan, lihat tabel referensi berikut untuk memilih URI gambar dan konfigurasi instance.

Memilih URI gambar

Resep	URI citra
URI gambar evaluasi	<code>708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-TJ-Eval-V2-latest</code>

Memilih jenis dan hitungan instans

Model	Jenis Tugas	Tipe instans	Jumlah instans yang disarankan	Jumlah instans yang diizinkan
Amazon Nova Mikro	Evaluasi (SFT/ DPO)	g5.12xlarge	1	1 - 16
Amazon Nova Lite	Evaluasi (SFT/ DPO)	g5.12xlarge	1	1 - 16
Amazon Nova Pro	Evaluasi (SFT/ DPO)	p5.48xlarge	1	1 - 16

Notebook sampel

Contoh notebook berikut menunjukkan bagaimana menjalankan pekerjaan pelatihan evaluasi.

```
# 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})

```

Menilai dan menganalisis hasil evaluasi

Setelah pekerjaan evaluasi Anda selesai dengan sukses, Anda dapat menilai dan menganalisis hasilnya menggunakan langkah-langkah berikut.

Untuk menilai dan menganalisis hasil, ikuti langkah-langkah ini.

1. Memahami struktur lokasi output. Hasil disimpan di lokasi keluaran Amazon S3 yang Anda tentukan sebagai file terkompresi:

```

s3://your-bucket/output/benchmark-name/
### job_name/
    ### output/
        ### output.tar.gz

```

2. Unduh `output.tar.gz` file dari ember Anda. Ekstrak konten untuk mengungkapkan.

```

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`- Keluaran metrik file JSON
 - `details_<task_name>_#_<datetime>.parquet`- File keluaran inferensi (kecuali `untukstrong_reject`)
 - `events.out.tfevents.[timestamp]`- Berkas TensorBoard keluaran
 - `inference_output.jsonl`- File output inferensi dibersihkan (hanya untuk `gen_qa` tugas)
3. Lihat hasil di TensorBoard. Untuk memvisualisasikan metrik evaluasi Anda:
1. Unggah folder yang diekstrak ke bucket S3
 2. Arahkan ke SageMaker AI TensorBoard
 3. Pilih "folder S3" Anda
 4. Tambahkan jalur folder S3
 5. Tunggu sinkronisasi selesai
4. Menganalisis output inferensi. Semua tugas evaluasi, kecuali `llm_judge` dan `strong_reject`, akan memiliki bidang berikut untuk analisis dalam output inferensi.
- `full_prompt`- Permintaan pengguna penuh dikirim ke model yang digunakan untuk tugas evaluasi.
 - `gold`- Bidang yang berisi jawaban yang benar seperti yang ditentukan oleh dataset.
 - `metrics`- Bidang yang berisi metrik yang dievaluasi pada inferensi individu. Nilai yang membutuhkan agregasi tidak akan memiliki nilai pada output inferensi individu.
 - `predictions`- Bidang yang berisi daftar output model untuk prompt yang diberikan.
 - `pred_logits`- Bidang yang berisi token keluaran yang dipertimbangkan dan probabilitas log dari setiap token keluaran yang dikembalikan dalam konten pesan.

Dengan melihat bidang ini, Anda dapat menentukan penyebab perbedaan metrik dan memahami perilaku model yang disesuaikan.

Untuk `llm_judge`, file keluaran inferensi berisi bidang berikut di bawah bidang metrik per pasangan evaluasi.

- `forward_output`- Preferensi mentah hakim saat mengevaluasi secara berurutan (`Response_a`, `response_b`).
- `backward_output`- Preferensi mentah hakim saat mengevaluasi dalam urutan terbalik (`Response_b`, `response_a`).

- **Pairwise metrics**- Metrik yang dihitung per pasang evaluasi maju dan mundur termasuk `scores`, `b_scoresties`, `inference-score` dan `score`

 Note

Metrik agregat seperti hanya `winrate` tersedia di file hasil ringkasan, bukan per penilaian individu.

Untuk `gen_qa`, `inference_output.jsonl` file berisi bidang berikut untuk setiap objek JSON:

- `prompt` - Prompt akhir yang dikirimkan ke model
- `inferensi` - Output inferensi mentah dari model
- `gold` - Respon target dari dataset input
- `metadata` - String metadata dari dataset input jika disediakan

Evaluasi praktik terbaik dan pemecahan masalah

Praktik terbaik

Berikut ini mencantumkan beberapa praktik terbaik untuk proses evaluasi.

- Jaga jalur keluaran Anda diatur berdasarkan model dan tipe benchmark.
- Pertahankan konvensi penamaan yang konsisten untuk memudahkan pelacakan.
- Simpan hasil yang diekstraksi di lokasi yang aman.
- Pantau status TensorBoard sinkronisasi untuk pemuatan data yang berhasil.

Pemecahan masalah

Anda dapat menggunakan grup CloudWatch log `/aws/sagemaker/TrainingJobs` untuk melatih log kesalahan pekerjaan.

Kegagalan inti mesin

Masalah:

Jika Anda melihat:


```
RuntimeError: Engine core initialization failed.
```

Penyebab:

Meskipun ini adalah kesalahan umum yang dapat memiliki banyak penyebab, biasanya terjadi ketika ada ketidakcocokan antara pos pemeriksaan model yang Anda coba muat dan jenis model yang ditentukan. Misalnya Anda ingin mengevaluasi pos pemeriksaan model Nova 2.0 lite yang disetel dengan baik tetapi tipe model yang Anda berikan adalah tipe model 1.0. misalnya `amazon.nova-micro-v1:0:128k`

Pemetaan yang benar harus

```
model_type: amazon.nova-2-lite-v1:0:256k
model_name_or_path: nova-lite-2/prod # or s3://escrow_bucket/model_location
```

Pencegahan:

Periksa kembali apakah `model_name_or_path` dipetakan ke kanan `model_type` sebelum mengirimkan pekerjaan evaluasi.

Subtugas yang tersedia

Berikut daftar subtugas yang tersedia untuk evaluasi model di beberapa domain termasuk MMLU (Massive Multitask Language Understanding), BBH (Big Bench Hard), MATH, dan MMMU (Massive Multitask Multimodal Understanding). Subtugas ini memungkinkan Anda menilai kinerja model Anda pada kemampuan dan bidang pengetahuan tertentu.

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"  
]
```

Matematika

```
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",
```

Evaluasi model Nova Anda yang disesuaikan menggunakan berbagai metode dan metrik evaluasi.

Di bagian ini:

- [Evaluasi model penalaran](#)
- [Evaluasi RFT](#)
- [Menerapkan fungsi hadiah](#)

Evaluasi model penalaran

Ikhtisar

Dukungan model penalaran memungkinkan evaluasi dengan model Nova berkemampuan penalaran yang melakukan penalaran internal eksplisit sebelum menghasilkan tanggapan akhir. Fitur ini menggunakan kontrol tingkat API melalui `reasoning_effort` parameter untuk mengaktifkan atau menonaktifkan fungsionalitas penalaran secara dinamis, berpotensi meningkatkan kualitas respons untuk tugas analitis yang kompleks.

Model yang didukung

- `amazon.nova-2-lite-v 1:0:256 k`

Konfigurasi resep

Aktifkan penalaran dengan menambahkan `reasoning_effort` parameter ke inference bagian resep Anda:

```
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)
```

Menggunakan parameter reasing_effort

reasoning_effortParameter mengontrol perilaku penalaran untuk model berkemampuan penalaran.

Prasyarat

- Kompatibilitas model - Set reasoning_effort hanya ketika model_type menentukan model berkemampuan penalaran (saat ini) amazon.nova-2-lite-v1:0:256k
- Penanganan kesalahan - Menggunakan reasoning_effort dengan model yang tidak didukung akan gagal dengan ConfigValidationError: "Reasoning mode is enabled but model '{model_type}' does not support reasoning. Please use a reasoning-capable model or disable reasoning mode."

Pilihan yang tersedia

Opsi	Perilaku	Batas token	Kasus penggunaan
null (default)	Menonaktifkan mode penalaran	N/A	Evaluasi standar tanpa overhead penalaran

Opsi	Perilaku	Batas token	Kasus penggunaan
rendah	Memungkinkan penalaran dengan kendala	4.000 token untuk penalaran internal	Skenario yang membutuhkan penalaran ringkas; mengoptimalkan kecepatan dan biaya
tinggi	Memungkinkan penalaran tanpa kendala	Tidak ada batasan token pada penalaran internal	Masalah kompleks yang membutuhkan analisis dan step-by-step penalaran ekstensif

Metode pelatihan	Pilihan yang tersedia	Cara mengkonfigurasi
SFT (Penyetelan Penyesuaian yang Diawasi)	Tinggi atau Mati saja	Gunakan <code>reasing_enabled: true</code> (high) atau <code>reasoning_enabled: false</code> (off)
RFT (Penguatan Fine-Tuning)	Rendah, Tinggi, atau Mati	Gunakan <code>reasing_effort: low</code> atau <code>reasing_effort: high</code> . Hilangkan bidang untuk menonaktifkan.
Evaluasi	Rendah, Tinggi, atau Mati	Gunakan <code>reasing_effort: low</code> atau <code>reasing_effort: high</code> . Gunakan <code>null</code> untuk menonaktifkan.

Kapan mengaktifkan penalaran

Gunakan mode penalaran (**low** atau **high**) untuk

- Tugas pemecahan masalah yang kompleks (matematika, teka-teki logika, pengkodean)
- Pertanyaan analitis multi-langkah yang membutuhkan penalaran menengah
- Tugas di mana penjelasan atau step-by-step pemikiran terperinci meningkatkan akurasi
- Skenario di mana kualitas respons diprioritaskan daripada kecepatan

Gunakan mode non-penalaran (**null** atau hilangkan parameter) untuk

- Tanya Jawab sederhana atau pertanyaan faktual
- Tugas menulis kreatif
- Ketika waktu respons yang lebih cepat sangat penting
- Perbandingan kinerja di mana overhead penalaran harus dikecualikan
- Optimalisasi biaya saat penalaran tidak meningkatkan kinerja tugas

Pemecahan masalah

Kesalahan: “Mode penalaran diaktifkan tetapi model tidak mendukung penalaran”

Penyebab: `reasoning_effort` Parameter disetel ke nilai non-null, tetapi yang ditentukan `model_type` tidak mendukung penalaran.

Resolusi:

- Verifikasi jenis model Anda `amazon.nova-2-lite-v1:0:256k`
- Jika menggunakan model yang berbeda, beralihlah ke model berkemampuan penalaran atau hapus `reasoning_effort` parameter dari resep Anda

Evaluasi RFT

Apa itu evaluasi RFT?

Evaluasi RFT memungkinkan Anda menilai kinerja model Anda menggunakan fungsi hadiah khusus sebelum, selama, atau setelah pelatihan pembelajaran penguatan. Tidak seperti evaluasi standar yang menggunakan metrik yang telah ditentukan sebelumnya, Evaluasi RFT memungkinkan Anda menentukan kriteria keberhasilan Anda sendiri melalui fungsi Lambda yang menilai output model berdasarkan kebutuhan spesifik Anda.

Mengapa mengevaluasi dengan RFT?

Evaluasi sangat penting untuk menentukan apakah proses fine-tuning RL memiliki:

- Penyelarasan model yang ditingkatkan dengan kasus penggunaan spesifik dan nilai-nilai kemanusiaan Anda
- Mempertahankan atau meningkatkan kemampuan model pada tugas-tugas utama
- Menghindari efek samping yang tidak diinginkan seperti berkurangnya faktualitas, peningkatan verbositas, atau penurunan kinerja pada tugas-tugas lain

- Memenuhi kriteria keberhasilan khusus Anda seperti yang ditentukan oleh fungsi hadiah Anda

Kapan menggunakan evaluasi RFT

Gunakan Evaluasi RFT dalam skenario ini:

- Sebelum Pelatihan RFT: Tetapkan metrik dasar pada kumpulan data evaluasi Anda
- Selama Pelatihan RFT: Pantau kemajuan pelatihan dengan pos pemeriksaan menengah
- Setelah Pelatihan RFT: Validasi bahwa model akhir memenuhi kebutuhan Anda
- Membandingkan Model: Mengevaluasi beberapa versi model menggunakan kriteria hadiah yang konsisten

Note

Gunakan Evaluasi RFT saat Anda membutuhkan metrik khusus domain khusus. Untuk evaluasi tujuan umum (akurasi, kebingungan, BLEU), gunakan metode evaluasi standar.

Persyaratan format data

Struktur data masukan

Data input evaluasi RFT harus mengikuti format Fine-Tuning Penguatan OpenAI. Setiap contoh adalah objek JSON yang berisi:

- `messages`— Array giliran percakapan dengan system dan peran user
- `reference_answer`— Output yang diharapkan atau data kebenaran dasar yang digunakan oleh fungsi hadiah Anda untuk penilaian

Contoh format data

```
{
  "messages": [
    {
      "role": "user",
      "content": [
        {
```

```

        "type": "text",
        "text": "Solve for x. Return only JSON like {\"x\": <number>}. Equation: 2x +
5 = 13"
    }
]
},
"reference_answer": {
    "x": 4
}
}

```

Keterbatasan saat ini

- Hanya teks: Tidak ada input multimodal (gambar, audio, video) yang didukung
- Percakapan satu putaran: Hanya mendukung pesan pengguna tunggal (tidak ada dialog multi-putaran)
- Format JSON: Data input harus dalam format JSONL (satu objek JSON per baris)
- Output model: Evaluasi dilakukan pada penyelesaian yang dihasilkan dari model yang ditentukan

Mempersiapkan resep evaluasi Anda

Contoh notebook

Untuk contoh lengkap, lihat [Buku catatan evaluasi](#).

Contoh konfigurasi resep

```

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>

```

Fungsi hadiah preset

Dua fungsi hadiah preset (`prime_code` dan `prime_math`) tersedia sebagai lapisan Lambda untuk memudahkan integrasi dengan fungsi Lambda RFT Anda.

Ikhtisar

Fungsi preset ini memberikan kemampuan out-of-the-box evaluasi untuk:

- `prime_code`— Pembuatan kode dan evaluasi kebenaran
- `prime_math`— Penalaran matematis dan evaluasi pemecahan masalah

Pengaturan cepat

1. [Unduh layer Lambda dari rilis. nova-custom-eval-sdk](#)
2. Publikasikan lapisan Lambda menggunakan AWS Command Line Interface (AWS CLI):

```

aws lambda publish-layer-version \
  --layer-name preset-function-layer \
  --description "Preset reward function layer with dependencies" \
  --zip-file fileb://universal_reward_layer.zip \
  --compatible-runtimes python3.9 python3.10 python3.11 python3.12 \
  --compatible-architectures x86_64 arm64

```

3. Tambahkan layer ke fungsi Lambda Anda di AWS Management Console (Pilih layer preset-function-layer dari kustom dan tambahkan juga AWSSDKPandas-Python 312 untuk dependensi numpy).
4. Impor dan gunakan dalam kode Lambda Anda:

```
from prime_code import compute_score # For code evaluation
from prime_math import compute_score # For math evaluation
```

fungsi prime_code

Mengevaluasi tugas pembuatan kode Python dengan mengeksekusi kode terhadap kasus uji dan mengukur kebenaran.

Contoh format dataset masukan

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

Fitur utama

- Ekstraksi kode otomatis dari blok kode penurunan harga
- Deteksi fungsi dan pengujian berbasis panggilan
- Eksekusi kasus uji dengan perlindungan batas waktu
- Validasi sintaks dan pemeriksaan kompilasi
- Pelaporan kesalahan terperinci dengan traceback

fungsi prime_math

Mengevaluasi penalaran matematika dan kemampuan pemecahan masalah dengan dukungan matematika simbolis.

Format masukan

```
{"messages":[{"role":"user","content":"What is the derivative of  $x^2 + 3x?$ ."}], "reference_answer": "2*x + 3"}
```

Fitur utama

- Evaluasi matematika simbolik menggunakan SymPy
- Beberapa format jawaban (LaTeX, teks biasa, simbolik)
- Pemeriksaan kesetaraan matematika
- Normalisasi dan penyederhanaan ekspresi

Persyaratan format data

Untuk evaluasi kode

- Input: Array argumen fungsi (tipe yang tepat: bilangan bulat, string, dll.)
- Output: Array nilai pengembalian yang diharapkan (tipe yang tepat: boolean, angka, dll.)
- Kode: Harus menggunakan Python dengan definisi fungsi yang jelas

Untuk evaluasi matematika

- Jawaban referensi: Ekspresi matematika atau nilai numerik
- Tanggapan: Bisa LaTeX, teks biasa, atau notasi simbolik
- Kesetaraan: Diperiksa secara simbolis, bukan hanya pencocokan string

Praktik terbaik

- Gunakan tipe data yang tepat dalam kasus uji (bilangan bulat vs string, boolean vs “True”)
- Berikan tanda tangan fungsi yang jelas dalam masalah kode
- Sertakan kasus tepi dalam input pengujian (nol, angka negatif, input kosong)
- Format ekspresi matematika secara konsisten dalam jawaban referensi
- Uji fungsi reward Anda dengan data sampel sebelum penerapan

Penanganan kesalahan

Kedua fungsi tersebut mencakup penanganan kesalahan yang kuat untuk:

- Kesalahan kompilasi dalam kode yang dihasilkan
- Pengecualian runtime selama eksekusi
- Data masukan cacat
- Skenario batas waktu untuk loop tak terbatas
- Ekspresi matematika tidak valid

Membuat fungsi hadiah Anda

Persyaratan Lambda ARN

Lambda ARN Anda harus mengikuti format ini:

```
"arn:aws:lambda:*:*:function:*SageMaker*"
```

Jika Lambda tidak memiliki skema penamaan ini, pekerjaan akan gagal dengan kesalahan ini:

```
[ERROR] Unexpected error: lambda_arn must contain one of: ['SageMaker', 'sagemaker', 'Sagemaker'] when running on SMHP platform (Key: lambda_arn)
```

Format permintaan Lambda

Fungsi Lambda Anda menerima data dalam format ini:

```
[
  {
    "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

Struktur pesan mencakup content array bersarang, cocok dengan format data input. Pesan terakhir dengan peran nova_assistant berisi respons yang dihasilkan model.

Format respons Lambda

Fungsi Lambda Anda harus mengembalikan data dalam format ini:

```

[
  {
    "id": "sample-001",
    "aggregate_reward_score": 0.75,
    "metrics_list": [
      {
        "name": "accuracy",
        "value": 0.85,
        "type": "Metric"
      },
      {
        "name": "fluency",
        "value": 0.90,
        "type": "Reward"
      }
    ]
  }
]
```

```
]
```

Bidang respons

- `id`— Harus cocok dengan ID sampel input
- `aggregate_reward_score`— Skor keseluruhan (biasanya 0,0 hingga 1,0)
- `metrics_list`— Array metrik individu dengan:
 - `name`— Pengidentifikasi metrik (misalnya, “akurasi”, “kelancaran”)
 - `value`— Skor metrik (biasanya 0,0 hingga 1,0)
 - `type`— Baik “Metrik” (untuk pelaporan) atau “Hadiah” (digunakan dalam pelatihan)

Izin IAM

Izin yang diperlukan

Peran SageMaker eksekusi Anda harus memiliki izin untuk menjalankan fungsi Lambda Anda. Tambahkan kebijakan ini ke peran SageMaker eksekusi Anda:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "lambda:InvokeFunction"
      ],
      "Resource": "arn:aws:lambda:region:account-id:function:function-name"
    }
  ]
}
```

Peran pelaksanaan Lambda

Peran eksekusi fungsi Lambda Anda memerlukan izin eksekusi Lambda dasar:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
```



```
"Effect": "Allow",
"Action": [
    "logs:CreateLogGroup",
    "logs:CreateLogStream",
    "logs:PutLogEvents"
],
"Resource": "arn:aws:logs:*:*:*"
}
]
}
```

Jika fungsi Lambda Anda mengakses AWS layanan lain (misalnya, S3 untuk data referensi, DynamoDB untuk logging), tambahkan izin tersebut ke peran eksekusi Lambda.

Melaksanakan pekerjaan evaluasi

1. Siapkan data Anda - Format data evaluasi Anda sesuai dengan persyaratan format data dan unggah file JSONL Anda ke S3: `s3://your-bucket/eval-data/eval_data.jsonl`
2. Konfigurasi resep Anda — Perbarui resep sampel dengan konfigurasi Anda:
 - Setel `model_name_or_path` ke lokasi model Anda
 - Atur `lambda_arn` ke ARN fungsi reward Anda
 - Setel `output_s3_path` ke lokasi keluaran yang Anda inginkan
 - Sesuaikan `inference` parameter sesuai kebutuhan

Simpan resepnya sebagai `rft_eval_recipe.yaml`

3. Jalankan evaluasi - Jalankan pekerjaan evaluasi menggunakan buku catatan yang disediakan: Buku [catatan evaluasi](#)
4. Pantau kemajuan — Pantau pekerjaan evaluasi Anda melalui:
 - SageMaker Konsol: Periksa status pekerjaan dan log
 - CloudWatch Log: Lihat log eksekusi terperinci
 - Lambda Logs: Masalah fungsi hadiah debug

Memahami hasil evaluasi

Format output

Pekerjaan evaluasi menghasilkan hasil ke lokasi S3 yang Anda tentukan dalam format JSONL. Setiap baris berisi hasil evaluasi untuk satu sampel:

```
{
  "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

Output Pekerjaan Evaluasi RFT identik dengan format Respons Lambda. Layanan evaluasi melewati respons fungsi Lambda Anda tanpa modifikasi, memastikan konsistensi antara perhitungan hadiah Anda dan hasil akhir.

Menafsirkan hasil

Skor hadiah agregat

- Rentang: Biasanya 0,0 (terburuk) hingga 1,0 (terbaik), tetapi tergantung pada implementasi Anda
- Tujuan: Angka tunggal yang merangkum kinerja keseluruhan
- Penggunaan: Bandingkan model, lacak peningkatan selama pelatihan

Metrik individu

- Jenis Metrik: Metrik informasi untuk analisis
- Jenis Hadiah: Metrik yang digunakan selama pelatihan RFT
- Interpretasi: Nilai yang lebih tinggi umumnya menunjukkan kinerja yang lebih baik (kecuali jika Anda merancang metrik terbalik)

Tolok ukur kinerja

Apa yang dimaksud dengan kinerja “baik” tergantung pada kasus penggunaan Anda:

Rentang skor	Interpretasi	Tindakan
0,8 - 1,0	Sangat baik	Model siap untuk penyebaran
0,6 - 0,8	Baik	Perbaikan kecil mungkin bermanfaat
0,4 - 0,6	Adil	Diperlukan peningkatan yang signifikan
0,0 - 0,4	Miskin	Tinjau data pelatihan dan fungsi hadiah

Important

Ini adalah pedoman umum. Tentukan ambang batas Anda sendiri berdasarkan persyaratan bisnis, kinerja model dasar, kendala khusus domain, dan analisis biaya-manfaat pelatihan lebih lanjut.

Pemecahan masalah

Masalah umum

Isu	Penyebab	Solusi
Batas waktu Lambda	Perhitungan hadiah yang kompleks	Tingkatkan batas waktu Lambda atau optimalkan fungsi
Izin ditolak	Izin IAM tidak ada	Verifikasi SageMaker peran dapat memanggil Lambda
Skor tidak konsisten	Fungsi hadiah non-deterministik	Gunakan benih tetap atau logika deterministik

Isu	Penyebab	Solusi
Hasil yang hilang	Kesalahan Lambda tidak tertangkap	Tambahkan penanganan kesalahan komprehensif di Lambda

Daftar periksa debug

- Verifikasi data input mengikuti format yang benar dengan array konten bersarang
- Konfirmasikan Lambda ARN sudah benar dan fungsinya diterapkan
- Periksa izin IAM untuk → Pemanggilan SageMaker Lambda
- Tinjau CloudWatch log untuk kesalahan Lambda
- Validasi respons Lambda sesuai dengan format yang diharapkan

Praktik terbaik

- Mulai Sederhana: Mulailah dengan fungsi imbalan dasar dan ulangi
- Uji Lambda Secara Terpisah: Gunakan acara uji Lambda sebelum evaluasi penuh
- Validasi pada Dataset Kecil: Jalankan evaluasi pada subset sebelum dataset lengkap
- Kontrol Versi: Lacak versi fungsi hadiah bersama versi model
- Biaya Monitor: Pemanggilan Lambda dan waktu komputasi memengaruhi biaya
- Log Ekstensif: Gunakan pernyataan cetak di Lambda untuk debugging
- Atur Timeout dengan Tepat: Seimbangkan antara kesabaran dan biaya
- Metrik Dokumen: Tentukan dengan jelas apa yang diukur setiap metrik

Langkah selanjutnya

Setelah menyelesaikan evaluasi RFT:

- Jika hasilnya memuaskan: Terapkan model ke produksi
- Jika perbaikan diperlukan:
 - Sesuaikan fungsi hadiah
 - Kumpulkan lebih banyak data pelatihan
 - Ubah hiperparameter pelatihan

- Jalankan iterasi pelatihan RFT tambahan
- Pemantauan berkelanjutan: Evaluasi ulang secara berkala dengan data baru

Menerapkan fungsi hadiah

Ikhtisar

Fungsi hadiah (juga disebut pencetak gol atau grader) adalah komponen inti yang mengevaluasi respons model dan memberikan sinyal umpan balik untuk pelatihan. Ini harus diimplementasikan sebagai fungsi Lambda yang menerima respons model dan mengembalikan skor hadiah.

Format antarmuka

Fungsi reward Anda harus menerima dan mengembalikan data dalam format berikut:

Sampel sampel masukan untuk pelatihan

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

Contoh payload untuk hadiah lambda

Kontainer secara otomatis mengubah data Anda sebelum mengirimnya ke fungsi Lambda Anda dengan:

1. Menghasilkan respons model untuk setiap prompt
2. Menambahkan giliran asisten (respons yang dihasilkan) ke array pesan
3. Menambahkan id bidang unik untuk melacak

Fungsi Lambda Anda akan menerima data dalam format yang diubah ini:

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

Hadiah kontrak Lambda

```
def lambda_handler(event, context):
    return lambda_grader(event)

def lambda_grader(samples: list[dict]) -> list[dict]:
    """
    Args:
        samples: List of dictionaries in OpenAI format

    Example input:
    {
      "id": "123",
      "messages": [
        {
          "role": "user",
          "content": "Do you have a dedicated security team?"
        },
        {
          "role": "assistant",
```

```

        "content": "As an AI developed by Company, I don't have a
dedicated security team..."
    },
    # This section will be same as your training dataset
    "reference_answer": {
        "compliant": "No",
        "explanation": "As an AI developed by Company, I do not have a
traditional security team..."
    }
}

Returns:
List of dictionaries with reward scores:
{
    "id": str,                    # Same id as input sample
    "aggregate_reward_score": float, # Overall score for the sample
    "metrics_list": [            # OPTIONAL: Component scores
        {
            "name": str,          # Name of the component score
            "value": float,       # Value of the component score
            "type": str           # "Reward" or "Metric"
        }
    ]
}
"""

```

Bidang input dan output

Bidang input

Bidang	Deskripsi	Catatan tambahan
id	Pengidentifikasi unik untuk sampel	Bergema kembali dalam output. Format string
pesan	Riwayat obrolan yang dipesan dalam format OpenAI	Array objek pesan
pesan [].role	Pembicara pesan	Nilai umum: "pengguna", "asisten", "sistem"

Bidang	Deskripsi	Catatan tambahan
pesan [].content	Konten teks pesan	Tali polos
**metadata	Informasi bentuk bebas untuk membantu penilaian	Objek; bidang opsional yang dilewatkan dari data pelatihan

Bidang output

Bidang	Deskripsi	Catatan tambahan
id	Pengidentifikasi yang sama dengan sampel input	Harus cocok dengan masukan
aggregate_reward_score	Skor keseluruhan untuk sampel	Float (misalnya, 0,0—1,0 atau rentang yang ditentukan tugas)
metrics_list	Skor komponen yang membentuk agregat	Array objek metrik

Kendala teknis

- Batas batas waktu - 15 menit waktu eksekusi maksimum per pemanggilan Lambda
- Konkurensi - Harus menangani permintaan `rollout_worker_replicas * 64` bersamaan
- Keandalan - Harus menerapkan penanganan kesalahan yang tepat dan mengembalikan skor yang valid secara konsisten
- Kinerja - Optimalkan untuk eksekusi cepat (detik, bukan menit) untuk memungkinkan pelatihan yang efisien

Praktik terbaik

- Minimalkan panggilan API eksternal
- Gunakan algoritma dan struktur data yang efisien
- Menerapkan logika coba lagi untuk kegagalan sementara
- Cache perhitungan yang dapat digunakan kembali

- Uji secara menyeluruh sebelum pelatihan untuk memastikan eksekusi bebas bug

Menggunakan fungsi hadiah khusus

Menerapkan fungsi hadiah khusus ketika Anda memiliki kriteria evaluasi khusus tugas:

- Tentukan kriteria evaluasi - Tentukan apa yang membuat respons yang baik untuk tugas Anda
- Menerapkan fungsi Lambda - Buat fungsi Lambda mengikuti format antarmuka
- Uji secara lokal - Validasi fungsi Anda mengembalikan skor yang benar untuk input sampel
- Terapkan ke AWS — Menyebarkan Lambda Anda dan perhatikan ARN
- Konfigurasi resep — Tambahkan Lambda ARN ke bidang resep Anda `reward_lambda_arn`
- Uji dengan dataset kecil — Jalankan RFT dengan data minimal untuk memverifikasi integrasi

Izin IAM

Izin yang diperlukan

Peran SageMaker eksekusi Anda harus memiliki izin untuk menjalankan fungsi Lambda Anda. Tambahkan kebijakan ini ke peran SageMaker eksekusi Anda:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "lambda:InvokeFunction"
      ],
      "Resource": "arn:aws:lambda:region:account-id:function:function-name"
    }
  ]
}
```

Peran pelaksanaan Lambda

Peran eksekusi fungsi Lambda Anda memerlukan izin eksekusi Lambda dasar:

```
{
```

```
"Version": "2012-10-17",
"Statement": [
  {
    "Effect": "Allow",
    "Action": [
      "logs:CreateLogGroup",
      "logs:CreateLogStream",
      "logs:PutLogEvents"
    ],
    "Resource": "arn:aws:logs:*:*:*"
  }
]
```

Izin tambahan: Jika fungsi Lambda Anda mengakses layanan AWS lain (misalnya, S3 untuk data referensi, DynamoDB untuk logging), tambahkan izin tersebut ke peran eksekusi Lambda.

Contoh: LLM Sebagai fungsi hadiah Hakim

Contoh ini menunjukkan penggunaan model Amazon Bedrock sebagai juri untuk mengevaluasi respons model dengan membandingkannya dengan jawaban referensi. Template Lambda ini menyediakan kerangka kerja bagi pelanggan untuk mengimplementasikan panggilan ke Amazon Bedrock untuk permintaan inferensi guna memproses evaluasi penilaian. Fungsi Lambda mempertahankan input/output kontrak yang sama dengan fungsi hadiah lainnya.

Implementasi

Fungsi Lambda ini mengimplementasikan proses evaluasi dua tahap: `lambda_handler` mengekstrak respons model dan jawaban referensi dari sampel yang masuk, kemudian fungsi tersebut `lambda_graded` memanggil Amazon Bedrock untuk menilai kesamaan semantik di antara mereka. Implementasinya mencakup penanganan kesalahan yang kuat dengan percobaan ulang otomatis untuk kegagalan sementara dan mendukung format jawaban referensi yang fleksibel (baik format string dan kamus terstruktur).

Detail implementasi:

- Coba Ulang Logika: Menerapkan backoff eksponensial (1s, 2s, 4s) untuk pengecualian pembatasan guna menangani batas laju API Bedrock
- Penanganan Kesalahan: Mengembalikan skor 0,0 untuk evaluasi yang gagal daripada menaikkan pengecualian

- **Penilaian Deterministik:** Menggunakan suhu = 0,0 untuk memastikan skor yang konsisten di seluruh evaluasi
- **Format Referensi Fleksibel:** Secara otomatis menangani jawaban referensi string dan kamus
- **Penjepitan Skor:** Memastikan semua skor berada dalam kisaran [0,0, 1,0] yang valid
- **Model Agnostik:** Ubah JUDGE_MODEL_ID untuk menggunakan model Amazon Bedrock apa pun (Nova, Llama, Mistral, dll.)

```

"""
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)})}

```

Format input

Lambda menerima format input yang sama dengan fungsi reward lainnya:

```

{
    "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"
}

```

Format output

```

{
  "id": "sample-001",
  "aggregate_reward_score": 0.85,
  "metrics_list": [
    {
      "name": "similarity_score",
      "value": 0.85,
      "type": "Metric"
    }
  ]
}

```

Pertimbangan deployment

Anda mungkin juga perlu menyesuaikan template prompt dan parameter inferensi berdasarkan kemampuan model dan format API yang Anda pilih.

- Izin IAM: Peran eksekusi Lambda harus memiliki `bedrock:InvokeModel` izin untuk model yang Anda pilih
- Timeout: Setel batas waktu Lambda setidaknya 60 detik untuk mengakomodasi latensi API Bedrock dan percobaan ulang
- Wilayah: Terapkan di wilayah tempat model Bedrock pilihan Anda tersedia

- Biaya: Pantau penggunaan API Bedrock karena setiap evaluasi membuat satu panggilan API per sampel
- Throughput: Untuk evaluasi skala besar, mintalah peningkatan kuota Bedrock untuk menghindari pembatasan

Meningkatkan Throughput Batuan Dasar

Jika Anda mengalami pelambatan selama evaluasi, tingkatkan kuota model Bedrock Anda:

- Arahkan ke konsol AWS Service Quotas
- Cari “Bedrock” dan pilih wilayah Anda
- Temukan kuota untuk model yang Anda pilih (misalnya, “Doa per menit untuk Claude 3.5 Soneta”)
- Klik “Minta peningkatan kuota” dan tentukan throughput yang Anda inginkan
- Berikan pembenaran untuk kenaikan (misalnya, “beban kerja evaluasi RFT”)

Logika coba ulang bawaan Lambda menangani pelambatan sesekali, tetapi evaluasi volume tinggi yang berkelanjutan memerlukan peningkatan kuota yang sesuai.

Kebijakan IAM yang Diperlukan:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "bedrock:InvokeModel"
      ],
      "Resource": "arn:aws:bedrock:*::foundation-model/*"
    }
  ]
}
```

Pelatihan berulang

Pelatihan berulang adalah pendekatan sistematis untuk menyempurnakan model melalui beberapa siklus pelatihan, di mana setiap putaran dibangun di atas pos pemeriksaan sebelumnya dengan mengatasi kelemahan spesifik yang ditemukan melalui evaluasi. Metode ini memungkinkan

peningkatan yang ditargetkan untuk memodelkan kinerja dengan memasukkan contoh yang dikuratori yang membahas mode kegagalan, beradaptasi dengan perubahan persyaratan, dan memvalidasi peningkatan secara bertahap daripada berkomitmen pada satu pelatihan jangka panjang. Prosesnya biasanya mengikuti pola seperti SFT (Supervised Fine-Tuning) diikuti oleh RFT (Reward-based Fine-Tuning), dengan pos pemeriksaan yang disimpan dalam bucket S3 escrow yang AWS dikelola yang dapat direferensikan untuk iterasi pelatihan berikutnya sambil mempertahankan konsistensi dalam jenis model dan teknik pelatihan di seluruh pipeline.

Untuk detail selengkapnya, lihat [???](#).

Kustomisasi Amazon Nova aktif SageMaker HyperPod

Anda dapat menyesuaikan model Amazon Nova, termasuk model Amazon Nova 2.0 yang disempurnakan, menggunakan [resep Amazon Nova](#) dan melatihnya di Hyperpod. Resep adalah file konfigurasi YAMM yang memberikan detail ke SageMaker AI tentang cara menjalankan pekerjaan penyesuaian model Anda. SageMaker HyperPod mendukung dua jenis layanan: Forge dan Non-Forge.

Hyperpod menawarkan komputasi berkinerja tinggi dengan instans GPU yang dioptimalkan dan FSx Amazon untuk penyimpanan Lustre, pemantauan yang kuat melalui integrasi dengan alat TensorBoard seperti, manajemen pos pemeriksaan yang fleksibel untuk peningkatan berulang, penyebaran tanpa batas ke Amazon Bedrock untuk inferensi, dan pelatihan terdistribusi multi-node yang efisien yang dapat diskalakan - semuanya bekerja sama untuk menyediakan organisasi dengan lingkungan yang aman, berkinerja, dan fleksibel untuk menyesuaikan model Amazon Nova dengan kebutuhan bisnis spesifik mereka.

Kustomisasi Amazon Nova pada artefak model SageMaker HyperPod toko termasuk pos pemeriksaan model dalam bucket Amazon S3 yang dikelola layanan. Artefak dalam bucket yang dikelola layanan dienkripsi dengan kunci yang dikelola AI. SageMaker AWS KMS Bucket Amazon S3 yang dikelola layanan saat ini tidak mendukung enkripsi data menggunakan kunci KMS yang dikelola pelanggan. Anda dapat menggunakan lokasi pos pemeriksaan ini untuk pekerjaan evaluasi atau inferensi Amazon Bedrock.

Harga standar dapat berlaku untuk instans komputasi, penyimpanan Amazon S3, dan untuk Lustre. FSx Untuk detail harga, lihat Harga [Hyperpod](#), [harga Amazon S3](#), [FSx dan untuk](#) harga Lustre.

Persyaratan komputasi untuk model Amazon Nova 2

Tabel berikut merangkum persyaratan komputasi untuk SageMaker HyperPod dan pelatihan pekerjaan pelatihan SageMaker AI untuk model Amazon Nova 2.

Persyaratan Pelatihan Nova 2

Teknik Pelatihan	Contoh Minimum	Tipe Instans	Hitungan GPU	Catatan	Model yang Didukung
SFT (LoRa)	4	P5.48xBesar	16	Penyetelan halus yang hemat parameter	Nova 2 Lite
SFT (Peringkat Penuh)	4	P5.48xBesar	32	Penyetelan halus model lengkap	Nova 2 Lite
RFT tentang Pekerjaan SageMaker Pelatihan (LoRa)	2	P5.48xBesar	16	Fungsi Hadiah Kustom di AWS Lingkungan Anda	Nova 2 Lite
RFT pada Pekerjaan SageMaker Pelatihan (Peringkat Penuh)	4	P5.48xBesar	32	Panjang konteks 32K	Nova 2 Lite
RFT pada SageMaker HyperPod	8	P5.48xBesar	64	Panjang konteks standar 8192	Nova 2 Lite
CPT	4	P5.48xBesar	16	Memproses sekitar 400	Nova 2 Lite

Teknik Pelatihan	Contoh Minimum	Tipe Instans	Hitungan GPU	Catatan	Model yang Didukung
				juta token per instans per hari	

Untuk mengoptimalkan alur kerja penyesuaian model Amazon Nova Anda di Hyperpod, ikuti praktik terbaik yang direkomendasikan ini untuk pelatihan yang efisien, manajemen sumber daya, dan penerapan model yang berhasil.

Praktik Terbaik untuk kustomisasi Amazon Nova

Ikhtisar

Bagian ini memberikan ikhtisar teknik penyesuaian dan membantu Anda memilih pendekatan terbaik untuk kebutuhan dan data yang tersedia.

Dua tahap pelatihan LLM

Pelatihan model bahasa besar terdiri dari dua tahap utama: pra-pelatihan dan pasca-pelatihan. Selama pra-pelatihan, model memproses token teks mentah dan mengoptimalkan prediksi token berikutnya. Proses ini menciptakan pelengkap pola yang menyerap sintaks, semantik, fakta, dan pola penalaran dari web dan teks yang dikuratori. Namun, model yang telah dilatih sebelumnya tidak memahami instruksi, tujuan pengguna, atau perilaku yang sesuai dengan konteks. Ini melanjutkan teks dalam gaya apa pun yang sesuai dengan distribusi pelatihannya. Model pra-terlatih melengkapi secara otomatis daripada mengikuti petunjuk, menghasilkan pemformatan yang tidak konsisten, dan dapat mencerminkan bias yang tidak diinginkan atau konten yang tidak aman dari data pelatihan. Pra-pelatihan membangun kompetensi umum, bukan kegunaan tugas.

Pasca-pelatihan mengubah pelengkap pola menjadi asisten yang berguna. Anda menjalankan beberapa putaran Supervised Fine-Tuning (SFT) untuk mengajarkan model mengikuti instruksi, mematuhi skema dan kebijakan, memanggil alat, dan menghasilkan output yang andal dengan meniru demonstrasi berkualitas tinggi. Penyelarasan ini mengajarkan model untuk menanggapi permintaan sebagai tugas daripada teks untuk melanjutkan. Anda kemudian menerapkan Reinforcement Fine-Tuning (RFT) untuk mengoptimalkan perilaku menggunakan umpan balik yang terukur (seperti verifier atau an LLM-as-a-judge), menyeimbangkan trade-off seperti akurasi versus singkatnya, keamanan versus cakupan, atau penalaran multi-langkah di bawah kendala. Dalam

praktiknya, Anda mengganti SFT dan RFT dalam siklus untuk membentuk model yang telah dilatih sebelumnya menjadi sistem yang andal dan selaras dengan kebijakan yang melakukan tugas-tugas kompleks secara konsisten.

Pilih pendekatan kustomisasi yang tepat

Pada bagian ini kita akan membahas strategi penyesuaian pasca pelatihan: RFT dan SFT.

Penyetelan halus penguatan (RFT)

Penyetelan halus penguatan meningkatkan kinerja model melalui sinyal umpan balik — skor terukur atau penghargaan yang menunjukkan kualitas respons — daripada pengawasan langsung dengan jawaban yang benar dan tepat. Tidak seperti fine-tuning tradisional yang diawasi yang belajar dari pasangan input-output, RFT menggunakan fungsi hadiah untuk mengevaluasi respons model dan secara iteratif mengoptimalkan model untuk memaksimalkan penghargaan ini. Pendekatan ini bekerja dengan baik untuk tugas-tugas di mana mendefinisikan output yang benar secara tepat menantang, tetapi Anda dapat mengukur kualitas respons dengan andal. RFT memungkinkan model untuk mempelajari perilaku dan preferensi yang kompleks melalui uji coba dan umpan balik, menjadikannya ideal untuk aplikasi yang memerlukan pengambilan keputusan bernuansa, pemecahan masalah yang kreatif, atau kepatuhan terhadap kriteria kualitas tertentu yang dapat Anda evaluasi secara terprogram. Misalnya, menjawab pertanyaan hukum yang kompleks adalah kasus penggunaan yang ideal untuk RFT karena Anda ingin mengajarkan model bagaimana bernalar lebih baik untuk menjawab pertanyaan dengan lebih akurat.

Cara kerjanya

Dalam penyempurnaan penguatan, Anda mulai dari garis dasar yang disetel instruksi dan memperlakukan setiap prompt seperti turnamen kecil. Untuk masukan yang diberikan, Anda mengambil sampel beberapa jawaban kandidat dari model, menilai masing-masing dengan fungsi hadiah, lalu memberi peringkat dalam kelompok itu. Langkah pembaruan mendorong model untuk membuat kandidat dengan skor lebih tinggi lebih mungkin di lain waktu dan yang mendapat skor lebih rendah lebih kecil kemungkinannya, sementara stay-close-to-baseline kendala membuat perilaku tidak melayang atau menjadi bertele-tele atau eksploitatif. Anda mengulangi loop ini melalui banyak petunjuk, menyegarkan hard case, mengencangkan verifier atau menilai rubrik saat Anda melihat eksploitasi, dan terus melacak metrik tugas.

Kapan menggunakan RFT

Tugas yang paling diuntungkan dari RFT memiliki beberapa sifat. Mereka memiliki sinyal keberhasilan yang terukur bahkan ketika satu output yang benar sulit ditentukan. Mereka mengakui

kredit sebagian atau kualitas bertingkat sehingga Anda dapat memberi peringkat yang lebih baik dibandingkan jawaban yang lebih buruk dalam prompt atau menggunakan fungsi hadiah. Mereka melibatkan beberapa tujuan yang harus seimbang (seperti akurasi dengan singkatnya, kejelasan, keamanan, atau biaya). Mereka membutuhkan kepatuhan terhadap batasan eksplisit yang dapat Anda periksa secara terprogram. Mereka beroperasi dalam pengaturan yang dimediasi alat atau berbasis lingkungan di mana hasil dapat diamati (keberhasilan atau kegagalan, latensi, penggunaan sumber daya). Mereka terjadi dalam rezim label rendah di mana mengumpulkan target emas mahal tetapi umpan balik otomatis atau berbasis rubrik berlimpah. RFT bekerja paling baik ketika Anda dapat mengubah kualitas menjadi skalar atau peringkat yang andal dan ingin model tersebut secara istimewa memperkuat perilaku dengan skor lebih tinggi tanpa memerlukan target berlabel lengkap.

Pertimbangkan metode lain ketika:

- Anda memiliki pasangan input-output berlabel yang berlimpah dan andal - Gunakan SFT
- Kesenjangan utama adalah pengetahuan atau jargon — Gunakan retrieval-augmented generation (RAG)
- Sinyal hadiah Anda berisik atau tidak dapat diandalkan dan Anda tidak dapat memperbaikinya dengan rubrik atau catur yang lebih baik — Stabilkan itu terlebih dahulu sebelum RFT

Kapan tidak menggunakan RFT

Hindari RFT dalam situasi ini:

- Anda dapat dengan mudah menghasilkan pasangan input-output berlabel yang andal (SFT lebih sederhana, lebih murah, dan lebih stabil)
- Kesenjangan adalah pengetahuan atau jargon daripada perilaku (gunakan RAG)
- Sinyal hadiah Anda berisik, jarang, mudah dimainkan, atau mahal atau lambat untuk dihitung (perbaiki evaluator terlebih dahulu)
- Kinerja dasar mendekati nol (bootstrap dengan SFT sebelum mengoptimalkan preferensi)
- Tugas ini memiliki skema deterministik, pemformatan ketat, atau satu jawaban yang benar (SFT atau validasi berbasis aturan bekerja lebih baik)
- Latensi ketat atau anggaran biaya tidak dapat menyerap pengambilan sampel tambahan atau eksplorasi yang dibutuhkan RFT
- Kendala keamanan atau kebijakan tidak ditentukan secara jelas dan dapat ditegakkan dalam hadiah

Jika Anda dapat menunjuk ke “jawaban yang benar,” gunakan SFT. Jika Anda membutuhkan pengetahuan baru, gunakan RAG. Gunakan RFT hanya setelah Anda memiliki baseline yang solid dan fungsi hadiah yang kuat, cepat, hard-to-exploit dan kuat.

Penyetelan halus yang diawasi (SFT)

Penyetelan halus yang diawasi melatih LLM pada kumpulan data pasangan input-output berlabel manusia untuk tugas Anda. Anda memberikan contoh petunjuk (pertanyaan, instruksi, dan sebagainya) dengan tanggapan yang benar atau diinginkan, dan terus melatih model pada contoh-contoh ini. Model menyesuaikan bobotnya untuk meminimalkan kerugian yang diawasi (biasanya lintas entropi antara prediksi dan token keluaran target). Ini adalah pelatihan yang sama yang digunakan dalam sebagian besar tugas pembelajaran mesin yang diawasi, diterapkan untuk mengkhususkan LLM.

SFT mengubah perilaku, bukan pengetahuan. Itu tidak mengajarkan model fakta atau jargon baru yang tidak dilihatnya dalam pra-pelatihan. Ini mengajarkan model bagaimana menjawab, bukan apa yang harus diketahui. Jika Anda membutuhkan pengetahuan domain baru (seperti terminologi internal), gunakan retrieval-augmented generation (RAG) untuk menyediakan konteks itu pada waktu inferensi. SFT kemudian menambahkan perilaku mengikuti instruksi yang diinginkan di atas.

Cara kerjanya

SFT mengoptimalkan LLM dengan meminimalkan kerugian lintas entropi rata-rata pada token respons, memperlakukan token prompt sebagai konteks dan menutupinya dari kerugian. Model menginternalisasi gaya target, struktur, dan aturan keputusan Anda, belajar untuk menghasilkan penyelesaian yang benar untuk setiap prompt. Misalnya, untuk mengklasifikasikan dokumen ke dalam kategori kustom, Anda menyempurnakan model dengan petunjuk (teks dokumen) dan pelengkapan berlabel (label kategori). Anda melatih pasangan tersebut sampai model mengeluarkan label yang tepat untuk setiap prompt dengan probabilitas tinggi.

Anda dapat melakukan SFT dengan sedikitnya beberapa ratus contoh dan skala hingga beberapa ratus ribu. Sampel SFT harus berkualitas tinggi dan langsung selaras dengan perilaku model yang diinginkan.

Kapan menggunakan SFT

Gunakan SFT ketika Anda memiliki tugas yang terdefinisi dengan baik dengan output yang diinginkan dengan jelas. Jika Anda dapat secara eksplisit menyatakan “Diberikan input X, output yang benar adalah Y” dan mengumpulkan contoh pemetaan tersebut, fine-tuning yang diawasi adalah pilihan yang baik. SFT unggul dalam skenario ini:

- Tugas klasifikasi terstruktur atau kompleks - Klasifikasi dokumen atau kontrak internal ke dalam banyak kategori khusus. Dengan SFT, model mempelajari kategori spesifik ini lebih baik daripada mendorong saja.
- Tugas penjawab pertanyaan atau transformasi dengan jawaban yang diketahui - Sempurnakan model untuk menjawab pertanyaan dari basis pengetahuan perusahaan, atau mengonversi data antar format di mana setiap input memiliki respons yang benar.
- Pemformatan dan konsistensi gaya - Latih model untuk selalu merespons dalam format atau nada tertentu dengan menyempurnakan contoh format atau nada yang benar. Misalnya, pelatihan pada pasangan respons cepat yang menunjukkan suara merek tertentu mengajarkan model untuk menghasilkan output dengan gaya itu. Perilaku mengikuti instruksi sering kali awalnya diajarkan melalui SFT pada contoh perilaku asisten yang baik yang dikuratori.

SFT adalah cara paling langsung untuk mengajarkan LLM keterampilan atau perilaku baru ketika Anda dapat menentukan seperti apa perilaku yang benar. Ini menggunakan pemahaman bahasa model yang ada dan memfokuskannya pada tugas Anda. Gunakan SFT ketika Anda ingin model melakukan hal tertentu dan Anda memiliki atau dapat membuat kumpulan data contoh.

Gunakan SFT saat Anda dapat merakit pasangan prompt dan respons berkualitas tinggi yang mencerminkan perilaku yang Anda inginkan. Ini cocok dengan tugas dengan target yang jelas atau format deterministik seperti skema, fungsi atau panggilan alat, dan jawaban terstruktur di mana imitasi adalah sinyal pelatihan yang sesuai. Tujuannya adalah membentuk perilaku: mengajarkan model untuk memperlakukan petunjuk sebagai tugas, mengikuti instruksi, mengadopsi kebijakan nada dan penolakan, dan menghasilkan pemformatan yang konsisten. Rencanakan setidaknya ratusan demonstrasi, dengan kualitas data, konsistensi, dan deduplikasi lebih penting daripada volume mentah. Untuk pembaruan yang mudah dan hemat biaya, gunakan metode hemat parameter seperti Adaptasi Peringkat Rendah untuk melatih adaptor kecil sambil membiarkan sebagian besar tulang punggung tidak tersentuh.

Kapan tidak menggunakan SFT

Jangan gunakan SFT ketika kesenjangan adalah pengetahuan daripada perilaku. Itu tidak mengajarkan model fakta baru, jargon, atau peristiwa baru-baru ini. Dalam kasus tersebut, gunakan retrieval-augmented generation untuk membawa pengetahuan eksternal pada kesimpulan. Hindari SFT ketika Anda dapat mengukur kualitas tetapi tidak dapat memberi label satu jawaban yang benar. Gunakan penyetulan penguatan dengan imbalan yang dapat diverifikasi atau untuk mengoptimalkan hadiah tersebut LLM-as-a-judge secara langsung. Jika kebutuhan atau konten Anda sering berubah, andalkan pengambilan dan penggunaan alat daripada melatih ulang model.

Topik

- [Nova Forge SDK](#)
- [Membuat cluster SageMaker HyperPod EKS dengan grup instans terbatas \(RIG\)](#)
- [Panduan Perintah SageMaker HyperPod Penting Amazon](#)
- [Akses dan pengaturan Nova Forge untuk](#)
- [Pelatihan untuk model Amazon Nova](#)
- [Mengevaluasi model terlatih Anda](#)
- [Memantau HyperPod pekerjaan dengan MLflow](#)

Nova Forge SDK

Amazon Nova Forge SDK adalah SDK Python komprehensif yang menyediakan antarmuka terprogram terpadu untuk siklus hidup kustomisasi model Amazon Amazon Nova yang lengkap. SDK menyederhanakan penyesuaian model dengan menawarkan API tunggal yang konsisten untuk pelatihan, evaluasi, pemantauan, penerapan, dan inferensi di seluruh platform Amazon SageMaker dan Amazon Bedrock.

Untuk informasi selengkapnya, lihat [Nova Forge SDK](#).

Membuat cluster SageMaker HyperPod EKS dengan grup instans terbatas (RIG)

Untuk menyesuaikan model pada Hyperpod, infrastruktur yang diperlukan harus disiapkan. Untuk detail tentang menyiapkan kluster SageMaker HyperPod EKS dengan grup instans terbatas (RIG), kunjungi [lokakarya](#), yang menyediakan panduan terperinci tentang proses penyiapan.

Panduan Perintah SageMaker HyperPod Penting Amazon

Amazon SageMaker HyperPod menyediakan fungsionalitas baris perintah yang luas untuk mengelola alur kerja pelatihan. Panduan ini mencakup perintah penting untuk operasi umum, mulai dari menghubungkan ke kluster Anda hingga memantau kemajuan pekerjaan.

Prasyarat

Sebelum menggunakan perintah ini, pastikan Anda telah menyelesaikan pengaturan berikut:

- SageMaker HyperPod cluster dengan RIG dibuat (biasanya di us-east-1)

- Output bucket Amazon S3 yang dibuat untuk melatih artefak
- Peran IAM dikonfigurasi dengan izin yang sesuai
- Data pelatihan diunggah dalam format JSONL yang benar
- FSx untuk sinkronisasi Lustre selesai (verifikasi di log cluster pada pekerjaan pertama)

Topik

- [Memasang Resep CLI](#)
- [Menghubungkan ke kluster Anda](#)
- [Memulai pekerjaan pelatihan](#)
- [Memeriksa status pekerjaan](#)
- [Memantau log pekerjaan](#)
- [Listing lowongan kerja aktif](#)
- [Membatalkan pekerjaan](#)
- [Menjalankan pekerjaan evaluasi](#)
- [Masalah umum](#)

Memasang Resep CLI

Arahkan ke root repositori resep Anda sebelum menjalankan perintah instalasi.

Gunakan repositori Hyperpodrecipes jika menggunakan teknik kustomisasi Non Forge, untuk kustomisasi berbasis Forge lihat repositori resep khusus tempa.

Jalankan perintah berikut untuk menginstal SageMaker HyperPod CLI:

Note

Pastikan Anda tidak berada di lingkungan conda/anaconda/miniconda aktif atau lingkungan virtual lainnya

Jika ya, silakan keluar dari lingkungan menggunakan:

- `conda deactivate` untuk lingkungan conda/anaconda/miniconda
- `deactivate` untuk lingkungan virtual python

Jika Anda menggunakan teknik kustomisasi Non Forge, unduh sagemaker-hyperpod-recipes seperti yang ditunjukkan di bawah ini:

```
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
```

Jika Anda adalah Pelanggan Forge, Anda harus mengunduh resep menggunakan proses yang disebutkan di bawah ini.

```
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

Untuk menggunakan [lingkungan virtual baru](#) sebelum menjalankan `pip install -e .`, jalankan:

- `python -m venv nova_forge`
- `source nova_forge/bin/activate`
- Baris perintah Anda sekarang akan ditampilkan (`nova_forge`) di awal prompt Anda

- Ini memastikan tidak ada dependensi yang bersaing saat menggunakan CLI

Tujuan: Mengapa kita lakukan `install -e .?`

Perintah ini menginstal SageMaker HyperPod CLI dalam mode yang dapat diedit, memungkinkan Anda untuk menggunakan resep yang diperbarui tanpa menginstal ulang setiap kali. Ini juga memungkinkan Anda untuk menambahkan resep baru yang dapat diambil oleh CLI secara otomatis.

Menghubungkan ke klaster Anda

Hubungkan SageMaker HyperPod CLI ke cluster Anda sebelum menjalankan pekerjaan apa pun:

```
export AWS_REGION=us-east-1 && SageMaker HyperPod connect-cluster --cluster-name  
<your-cluster-name> --region us-east-1
```

Important

Perintah ini membuat file konteks (`/tmp/hyperpod_context.json`) yang dibutuhkan perintah berikutnya. Jika Anda melihat kesalahan tentang file ini tidak ditemukan, jalankan kembali perintah `connect`.

Kiat pro: Anda dapat mengonfigurasi klaster Anda lebih lanjut untuk selalu menggunakan `kubeflow` namespace dengan menambahkan `--namespace kubeflow` argumen ke perintah Anda sebagai berikut:

```
export AWS_REGION=us-east-1 && \  
hyperpod connect-cluster \  
--cluster-name <your-cluster-name> \  
--region us-east-1 \  
--namespace kubeflow
```

Ini menghemat upaya Anda untuk menambahkan `-n kubeflow` di setiap perintah saat berinteraksi dengan pekerjaan Anda.

Memulai pekerjaan pelatihan

Note

Jika menjalankan PPO/RFT pekerjaan, pastikan Anda menambahkan pengaturan pemilih label `src/hyperpod_cli/sagemaker_hyperpod_recipes/recipes_collection/cluster/k8s.yaml` agar semua pod dijadwalkan pada node yang sama.

```
label_selector:
  required:
    sagemaker.amazonaws.com/instance-group-name:
      - <rig_group>
```

Luncurkan pekerjaan pelatihan menggunakan resep dengan penggantian parameter opsional:

```
hyperpod start-job -n kubeflow \
--recipe fine-tuning/nova/nova_1_0/nova_micro/SFT/nova_micro_1_0_p5_p4d_gpu_lora_sft \
--override-parameters '{
"instance_type": "ml.p5.48xlarge",
  "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-
HP-SFT-latest"
}'
```

Output yang diharapkan:

```
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>"
}

```

Memeriksa status pekerjaan

Pantau pekerjaan Anda yang sedang berjalan menggunakan kubectl:

```
kubectl get pods -o wide -w -n kubeflow | (head -n1 ; grep <your-job-name>)
```

Memahami status pod

Tabel berikut menjelaskan status pod umum:

Status	Deskripsi
Pending	Pod diterima tetapi belum dijadwalkan ke node, atau menunggu gambar kontainer ditarik
Running	Pod terikat pada sebuah node dengan setidaknya satu kontainer berjalan atau dimulai
Succeeded	Semua kontainer berhasil diselesaikan dan tidak akan dimulai ulang
Failed	Semua kontainer diakhiri dengan setidaknya satu berakhir dengan kegagalan
Unknown	Status pod tidak dapat ditentukan (biasanya karena masalah komunikasi node)
CrashLoopBackOff	Container berulang kali gagal; Kubernetes mundur dari upaya restart

Status	Deskripsi
ImagePullBackOff / ErrImagePull	Tidak dapat menarik gambar kontainer dari registri
OOMKilled	Kontainer dihentikan karena melebihi batas memori
Completed	Job atau Pod berhasil diselesaikan (penyelesaian pekerjaan batch)

Tip

Gunakan `-w` bendera untuk menonton pembaruan status pod secara real-time. Tekan `Ctrl +C` untuk berhenti menonton.

Memantau log pekerjaan

Anda dapat melihat log Anda salah satu dari tiga cara:

Menggunakan CloudWatch

Log Anda tersedia di AWS akun Anda yang berisi Hyperpodcluster di bawah. CloudWatch Untuk melihatnya di browser Anda, navigasikan ke CloudWatch beranda di akun Anda dan cari nama cluster Anda. Misalnya, jika klaster Anda dipanggil `my-hyperpod-rig`, grup log akan memiliki awalan:

- Grup log: `/aws/sagemaker/Clusters/my-hyperpod-rig/{UUID}`
- Setelah Anda berada di grup log, Anda dapat menemukan log spesifik Anda menggunakan ID instance node seperti `-hyperpod-i-00b3d8a1bf25714e4`.
- `i-00b3d8a1bf25714e4` di sini mewakili nama mesin Hyperpodfriendly tempat pekerjaan pelatihan Anda berjalan. Ingat bagaimana dalam `kubectl get pods -o wide -w -n kubeflow | (head -n1 ; grep my-cpt-run)` output perintah sebelumnya kita menangkap kolom yang disebut NODE.

- Run node “master” dalam hal ini berjalan pada hyperpod- i-00b3d8a1bf25714e4 dan dengan demikian kita akan menggunakan string itu untuk memilih grup log untuk dilihat. Pilih salah satu yang mengatakan SagemakerHyperPodTrainingJob/rig-group/[NODE]

Menggunakan CloudWatch Wawasan

Jika Anda memiliki nama pekerjaan yang berguna dan tidak ingin melalui semua langkah di atas, Anda cukup menanyakan semua log di bawah /aws/sagemaker/Clusters/my-hyperpod-rig/{UUID} untuk menemukan log individu.

CPT:

```
fields @timestamp, @message, @logStream, @log
| filter @message like /(?!i)Starting CPT Job/
| sort @timestamp desc
| limit 100
```

Untuk penyelesaian pekerjaan ganti Starting CPT Job dengan CPT Job completed

Kemudian Anda dapat mengklik hasil dan memilih salah satu yang mengatakan “Epoch 0” karena itu akan menjadi node master Anda.

Menggunakan AWS CLI

Anda dapat memilih untuk membuntuti log Anda menggunakan AWS CLI. Sebelum melakukannya, periksa versi aws cli Anda menggunakan `aws --version`. Disarankan juga untuk menggunakan skrip utilitas ini yang membantu dalam pelacakan log langsung di terminal Anda

untuk V1:

```
aws logs get-log-events \
--log-group-name /aws/sagemaker/YourLogGroupName \
--log-stream-name YourLogStream \
--start-from-head | jq -r '.events[].message'
```

untuk V2:

```
aws logs tail /aws/sagemaker/YourLogGroupName \
--log-stream-name YourLogStream \
--since 10m \
```

```
--follow
```

Listing lowongan kerja aktif

Lihat semua pekerjaan yang berjalan di cluster Anda:

```
hyperpod list-jobs -n kubeflow
```

Contoh keluaran:

```
{
  "jobs": [
    {
      "Name": "test-run-nhgza",
      "Namespace": "kubeflow",
      "CreationTime": "2025-10-29T16:50:57Z",
      "State": "Running"
    }
  ]
}
```

Membatalkan pekerjaan

Hentikan pekerjaan yang sedang berjalan kapan saja:

```
hyperpod cancel-job --job-name <job-name> -n kubeflow
```

Menemukan nama pekerjaan Anda

Opsi 1: Dari resep Anda

Nama pekerjaan ditentukan di `run` blok resep Anda:

```
run:
  name: "my-test-run"                # This is your job name
  model_type: "amazon.nova-micro-v1:0:128k"
  ...
```

Opsi 2: Dari perintah daftar-pekerjaan

Gunakan `hyperpod list-jobs -n kubeflow` dan salin Name bidang dari output.

Menjalankan pekerjaan evaluasi

Mengevaluasi model terlatih atau model dasar menggunakan resep evaluasi.

Prasyarat

Sebelum menjalankan pekerjaan evaluasi, pastikan Anda memiliki:

- Checkpoint Amazon S3 URI dari file pekerjaan pelatihan Anda (untuk model `manifest.json` terlatih)
- Dataset evaluasi diunggah ke Amazon S3 dalam format yang benar
- Output jalur Amazon S3 untuk hasil evaluasi

Perintah

Jalankan perintah berikut untuk memulai pekerjaan evaluasi:

```
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"
  }'
```

Deskripsi parameter:

- `recipes.run.name`: Nama unik untuk pekerjaan evaluasi Anda
- `recipes.run.model_name_or_path`: Amazon S3 URI dari `manifest.json` atau jalur model dasar (mis.,) `nova-micro/prod`
- `recipes.run.output_s3_path`: Lokasi Amazon S3 untuk hasil evaluasi
- `recipes.run.data_s3_path`: Lokasi Amazon S3 dari kumpulan data evaluasi Anda

Kiat:

- Resep khusus model: Setiap ukuran model (mikro, lite, pro) memiliki resep evaluasi sendiri
- Evaluasi model dasar: Gunakan jalur model dasar (misalnya, nova-micro/prod) alih-alih pos pemeriksaan URIs untuk mengevaluasi model dasar

Format data evaluasi

Format masukan (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"
}
```

Format keluaran:

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

Deskripsi bidang:

- **prompt:** Input yang diformat dikirim ke model
- **inference:** Respons yang dihasilkan model
- **gold:** Diharapkan jawaban yang benar dari dataset input
- **metadata:** Metadata opsional dilewatkan dari input

Masalah umum

- **ModuleNotFoundError:** No module named 'nemo_launcher', Anda mungkin harus menambahkan `nemo_launcher` ke jalur python Anda berdasarkan tempat `hyperpod_cli` diinstal. Contoh perintah:

```
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'` menunjukkan Anda melewatkan menjalankan perintah `cluster hyperpod connect`.
- Jika Anda tidak melihat jadwal pekerjaan Anda, periksa kembali apakah output SageMaker HyperPod CLI Anda memiliki bagian ini dengan nama pekerjaan dan metadata lainnya. Jika tidak, instal ulang bagan helm dengan menjalankan:

```
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
```

Akses dan pengaturan Nova Forge untuk

Untuk mengatur Amazon Nova Forge untuk digunakan dengan Jobs, Anda perlu:

- Berlangganan Amazon Nova Forge
- Siapkan cluster

Topik

- [Berlangganan Amazon Nova Forge](#)
- [Menyiapkan infrastruktur](#)
- [AI yang bertanggung jawab](#)

Berlangganan Amazon Nova Forge

Untuk mengakses fitur Amazon Nova Forge, selesaikan langkah-langkah berikut:

1. Verifikasi akses administrator ke AWS akun.
2. Arahkan ke konsol SageMaker AI dan [minta akses ke Amazon Nova Forge](#).

3. Tunggu tim Amazon Nova mengirim email konfirmasi setelah permintaan berlangganan disetujui.
4. Tandai peran eksekusi Anda dengan `forge-subscription` tag. Tag ini diperlukan untuk mengakses fitur Amazon Nova Forge dan pos pemeriksaan. Tambahkan tag berikut ke peran eksekusi Anda:
 - Kunci: `forge-subscription`
 - Nilai: `true`

Note

Fitur Amazon Nova standar tetap tersedia tanpa berlangganan Forge. Amazon Nova Forge dirancang untuk membangun model perbatasan khusus dengan kontrol dan fleksibilitas di semua fase pelatihan model.

Menyiapkan infrastruktur

Setelah langganan Amazon Nova Forge Anda disetujui, siapkan infrastruktur yang diperlukan untuk menggunakan fitur berkemampuan Forge. Untuk petunjuk rinci tentang membuat kluster EKS dengan grup instans terbatas (RIG), ikuti instruksi [lokakarya](#).

AI yang bertanggung jawab

Pengaturan moderasi konten: Pelanggan Amazon Nova Forge memiliki akses ke Pengaturan Moderasi Konten yang Dapat Disesuaikan (CCMS) untuk model Amazon Nova Lite 1.0 dan Pro 1.0. CCMS memungkinkan Anda menyesuaikan kontrol moderasi konten agar sesuai dengan kebutuhan bisnis spesifik Anda sambil mempertahankan perlindungan AI yang bertanggung jawab. Untuk menentukan apakah kasus penggunaan bisnis Anda memenuhi syarat untuk CCM, hubungi manajer akun Amazon Web Services Anda.

Amazon Nova Forge menyediakan Toolkit AI Bertanggung Jawab yang mencakup data pelatihan, tolok ukur evaluasi, dan kontrol runtime untuk membantu Anda menyelaraskan model Anda dengan pedoman AI bertanggung jawab Amazon Nova.

Data pelatihan: Kategori “RAI” dalam pencampuran data berisi kasus dan skenario yang menekankan prinsip AI yang bertanggung jawab, pertimbangan keselamatan, dan penyebaran teknologi yang bertanggung jawab. Gunakan ini untuk menyelaraskan model Anda secara bertanggung jawab selama pra-pelatihan lanjutan.

Evaluasi: Tugas benchmark tersedia untuk menguji kemampuan model Anda dalam mendeteksi dan menolak konten yang tidak pantas, berbahaya, atau salah. Gunakan evaluasi ini untuk mengukur perbedaan antara kinerja model dasar dan kinerja model kustom Anda.

Pelatihan untuk model Amazon Nova

Melatih model Amazon Nova SageMaker HyperPod mendukung berbagai teknik termasuk Continued Pre-Training (CPT), Supervised Fine-Tuning (SFT), dan Reinforcement Fine-Tuning (RFT). Setiap teknik melayani kebutuhan kustomisasi yang berbeda dan dapat diterapkan ke versi model Amazon Nova yang berbeda.

Topik

- [Pra-pelatihan lanjutan \(CPT\)](#)
- [Penyetelan halus yang diawasi \(SFT\)](#)
- [Penguatan Fine-Tuning \(RFT\) aktif SageMaker HyperPod](#)

Pra-pelatihan lanjutan (CPT)

Pre-training lanjutan (CPT) adalah teknik pelatihan yang memperluas fase pra-pelatihan model yayasan dengan mengeksposnya ke teks tambahan yang tidak berlabel dari domain atau korpora tertentu. Tidak seperti fine-tuning yang diawasi, yang membutuhkan pasangan input-output berlabel, CPT melatih dokumen mentah untuk membantu model memperoleh pengetahuan yang lebih dalam tentang domain baru, mempelajari terminologi dan pola penulisan khusus domain, dan beradaptasi dengan jenis konten atau area subjek tertentu.

Pendekatan ini sangat berharga ketika Anda memiliki volume besar (puluhan miliar token) data teks khusus domain, seperti dokumen hukum, literatur medis, dokumentasi teknis, atau konten bisnis berpemilik, dan Anda ingin model tersebut mengembangkan kefasihan asli dalam domain itu. Umumnya, setelah tahap CPT, model perlu menjalani tahap penyetelan instruksi tambahan untuk memungkinkan model menggunakan pengetahuan yang baru diperoleh dan menyelesaikan tugas yang berguna.

Model yang didukung

CPT tersedia untuk model Amazon Nova berikut:

- Nova 1.0 (Mikro, Lite, Pro)
- Nova 2.0 (Ringan)

Kapan menggunakan Nova 1.0 versus Nova 2.0

Rangkaian model Amazon Nova menawarkan beberapa titik operasi kinerja harga untuk mengoptimalkan antara akurasi, kecepatan, dan biaya.

Pilih Nova 2.0 saat Anda membutuhkan yang berikut ini:

- Kemampuan penalaran tingkat lanjut untuk tugas analitis yang kompleks
- Kinerja unggul dalam pengkodean, matematika, dan pemecahan masalah ilmiah
- Dukungan panjang konteks yang lebih panjang
- Performa multibahasa yang lebih baik

Note

Model yang lebih besar tidak selalu lebih baik. Pertimbangkan tradeoff kinerja biaya dan persyaratan bisnis spesifik Anda saat memilih antara model Nova 1.0 dan Nova 2.0.

CPT pada Nova 2.0

Amazon Nova Lite 2.0 adalah model penalaran yang dilatih pada kumpulan data yang lebih besar dan lebih beragam daripada Nova Lite 1.0. Meskipun merupakan model yang lebih besar, Nova Lite 2.0 memberikan inferensi yang lebih cepat daripada Nova Lite 1.0 sambil menawarkan kemampuan penalaran yang ditingkatkan, panjang konteks yang lebih panjang, dan peningkatan kinerja multibahasa.

CPT di Nova 2.0 memungkinkan Anda untuk memperluas kemampuan canggih ini dengan data spesifik domain Anda, memungkinkan model untuk mengembangkan keahlian mendalam di bidang khusus sambil mempertahankan penalaran dan kemampuan analitisnya yang unggul.

Contoh resep CPT

Berikut ini adalah contoh resep untuk CPT. Anda dapat menemukan resep ini dan lainnya di repositori [resep](#).

```
# 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

```

Persiapan data untuk CPT pada 2.0

Persyaratan format data

Kumpulan data pelatihan dan validasi harus berupa file JSONL mengikuti format yang ditunjukkan di bawah ini, di mana setiap baris berisi objek JSON yang mewakili percakapan dengan bidang dan struktur yang diperlukan. Inilah contohnya:

```

{"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"}

```

Entri teks harus berisi konten berkualitas tinggi yang mengalir secara alami yang mewakili domain target.

Uji apakah data tersebut mampu diubah menjadi [format Arrow](#). Gunakan skrip python di bawah ini untuk membantunya. Pastikan datasets==2.18.0 versi minimal digunakan:

```

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)
```

Ini harus mencetak jumlah baris yang sama yang ada di file JSONL.

Saat menggunakan datamixing, jalankan pekerjaan pertama dengan `max_steps=2`. Ini akan membantu membuat pengoptimalan di cluster untuk akses data dan memvalidasi bahwa semua datamix tersedia.

Cara menyiapkan data untuk CPT

Data pelatihan adalah faktor penentu yang paling penting untuk keberhasilan pra-pelatihan berkelanjutan. Sementara data CPT sering digambarkan sebagai “tidak berlabel,” kenyataannya jauh lebih berruasa. Bagaimana data disusun, diformat, dan disajikan menentukan apakah model akan memperoleh pengetahuan dan keterampilan yang diperlukan untuk kasus penggunaan bisnis.

Mempersiapkan kumpulan data bisnis terstruktur untuk CPT

Ini adalah tantangan umum bagi perusahaan dan organisasi yang membangun model pondasi khusus dalam domain mereka. Sebagian besar bisnis memiliki repositori data terstruktur yang kaya: katalog produk, profil pengguna, log transaksi, pengiriman formulir, panggilan API, dan metadata operasional. Pada pandangan pertama, ini terlihat sangat berbeda dari teks web tidak terstruktur yang biasanya digunakan dalam pra-pelatihan standar.

Untuk belajar secara efektif dari data bisnis terstruktur, pikirkan baik-baik tentang tugas-tugas hilir dan rancang presentasi data untuk memaksa model mempelajari hubungan prediktif yang tepat.

Untuk membuka potensi penuh dari pra-pelatihan berkelanjutan, pertimbangkan:

- Tugas apa yang harus dilakukan model pada waktu inferensi
- Informasi apa yang ada dalam data mentah
- Bagaimana menyusun data itu sehingga model belajar mengekstrak dan memanipulasi informasi dengan benar

Cukup membuang data terstruktur ke dalam pelatihan tidak akan mengajarkan model untuk bernalar tentang hal itu. Secara aktif membentuk presentasi data untuk memandu apa yang dipelajari model.

Pada bagian berikut, ada tinjauan literatur yang menunjukkan pentingnya augmentasi data dan memberikan contoh strategi augmentasi untuk data bisnis terstruktur yang akan memberikan ide-ide berguna tentang bagaimana memperlakukan dan mengatur dataset bisnis untuk CPT.

Data terstruktur untuk CPT dalam literatur

CPT dapat mengemas fakta domain ke dalam model tetapi sering gagal membuat fakta tersebut dapat diambil dan dimanipulasi ketika input atau tugas bergeser. Eksperimen terkontrol menunjukkan bahwa tanpa augmentasi yang beragam selama pra-pelatihan, model menghafal fakta dengan cara rapuh yang tetap sulit untuk diekstraksi bahkan setelah penyetelan instruksi selanjutnya, dan mereka merekomendasikan penyuntikan instruksi seperti sinyal di awal pelatihan. Untuk data semi terstruktur, serialisasi acak dan augmentasi lainnya mengurangi overfitting skema, itulah sebabnya CPT harus disisipkan dengan tugas gaya instruksi daripada dijalankan terlebih dahulu dan IFT nanti. Pekerjaan yang berfokus pada keuangan lebih lanjut menemukan bahwa bersama-sama mencampur CPT dan data instruksi pada waktu batch meningkatkan generalisasi dan mengurangi lupa versus resep berurutan. Laporan teknis Qwen menyatu pada pola yang sama dengan mengintegrasikan data instruksi berkualitas tinggi ke dalam pra-pelatihan itu sendiri, yang meningkatkan pembelajaran konteks dan mempertahankan instruksi berikut sambil memperoleh pengetahuan domain baru.

Augmentasi data untuk korpora semi terstruktur adalah tuas kunci. CPT sadar grafik sintetis memperluas kumpulan domain kecil menjadi korpora terkait entitas yang secara eksplisit mengajarkan hubungan dan senyawa dengan pengambilan pada waktu inferensi. Gabungan CPT plus pencampuran instruksi mengungguli jaringan pipa berurutan di bidang keuangan dan menyeimbangkan domain dengan data umum menurunkan degradasi keterampilan umum. CPT domain skala sangat besar juga dapat mempertahankan kemampuan yang luas dan bahkan memungkinkan trade off melalui penggabungan model, namun masih menunjuk ke penyetelan instruksi sebagai langkah penting berikutnya, memperkuat nilai pengenalan sinyal instruksi selama CPT.

Menyuntikkan keragaman melalui pengacakan dan pengocokan

Strategi umum yang membantu mengajarkan model secara efektif dari kumpulan data terstruktur dan semi terstruktur adalah dengan mengacak urutan bidang dalam kumpulan data, dan bahkan secara acak mengeluarkan beberapa kunci.

Mengacak bidang memaksa model untuk membaca apa arti setiap nilai alih-alih di mana ia muncul dan mempelajari hubungan antara semua bidang. Misalnya, dalam kasus permainan video yang diposting di toko amazon, ketika “Judul,” “Platform,” “Harga,” “Kondisi,” dan “Edisi” tiba dalam permutasi yang berbeda, model tidak dapat mengandalkan “slot ketiga adalah platform”; itu harus mengikat label ke nilai dan mempelajari hubungan bilateral antara atribut: judul platform, harga platform, kondisi harga. Jadi dapat, misalnya, menyimpulkan kemungkinan platform dari nama game dan harga yang diamati, atau memperkirakan kisaran harga yang masuk akal yang diberikan judul dan platform.

Menjatuhkan kunci secara acak selama serialisasi bertindak seperti putus fitur: ini mencegah adaptasi bersama pada satu bidang dan memaksa model untuk memulihkan informasi yang hilang dari bukti yang tersisa. Jika “Platform” tidak ada, model harus mengambilnya dari string judul atau teks kompatibilitas; jika “Harga” disembunyikan, ia harus melakukan triangulasi dari platform, edisi, dan kondisi. Ini membangun simetri ($A \rightarrow B$ dan $B \rightarrow A$), ketahanan terhadap daftar dunia nyata yang berantakan, dan invarian skema saat bidang hilang, diganti namanya, atau disusun ulang.

Contoh gaya belanja membuatnya konkret. Serialisasi item yang sama dengan beberapa cara —“Judul: 'Elden Ring' | Platform: PlayStation 5 | Kondisi: Digunakan—Seperti Baru | Harga: \$34,99” dan permutasi seperti “Harga: \$34,99 | Judul: 'Elden Ring' | Kondisi: Digunakan — Seperti Baru | Platform: 5”—dan pada beberapa lintasan, jatuhkan “Platform” sambil meninggalkan “Kompatibel dengan” dalam deskripsi. PlayStation PS5 Latih tujuan pelengkap seperti memprediksi platform dari {title, price} dan memprediksi ember harga dari {title, platform}. Karena urutan dan bahkan kehadiran kunci bervariasi, satu-satunya strategi yang stabil adalah mempelajari hubungan sejati antara atribut daripada menghafal templat.

Cara data disajikan penting

LLMs belajar dengan memprediksi token berikutnya dari apa yang telah mereka lihat. Jadi urutan bidang dan acara yang ditampilkan selama pelatihan memutuskan apa yang dapat dipelajari model. Jika format pelatihan cocok dengan tugas sebenarnya, kerugian mendarat pada token keputusan yang tepat. Jika bidang dilemparkan bersama tanpa struktur, model mempelajari pintasan atau menghafal popularitas dan kemudian gagal ketika diminta untuk memilih di antara opsi.

Tunjukkan situasinya terlebih dahulu, lalu pilihannya, lalu keputusannya. Jika model juga harus belajar tentang hasil atau penjelasan, letakkan setelah keputusan.

Sampel pengepakan untuk CPT

Apa itu pengepakan?

Ini hanya berarti mengisi setiap jendela urutan dalam data pelatihan dengan beberapa contoh utuh sehingga jendela padat dengan token nyata, bukan padding.

Mengapa itu penting

Selama pelatihan panjang konteks maksimum ditetapkan, misalnya 8.192 token. Batch dibentuk menjadi [ukuran batch × panjang konteks]. Jika contoh pelatihan lebih pendek dari panjang konteks, posisi yang tersisa akan empuk. Padding masih berjalan melalui perhatian dan kernel MLP bahkan jika kerugian ditutupi, jadi komputasi dibayar untuk token yang tidak membawa sinyal pembelajaran.

Bagaimana cara melakukan pengepakan?

Untuk mengemas beberapa sampel, gabungkan beberapa sampel pelatihan dengan [DOC] pemisah di antaranya (perhatikan ruang sebelum dan sesudah [DOC]) sehingga panjang penuh sampel berada di bawah panjang konteks yang diinginkan.

Contoh dokumen yang dikemas akan terlihat seperti ini:

```
{"text": "training sample 1 [DOC] training sample 2 [DOC] training sample 3"}
```

Parameter Penyetelan CPT

Parameter yang tersedia untuk fine-tuning dengan CPT meliputi:

Jalankan Konfigurasi

- **nama:** Nama deskriptif untuk pekerjaan pelatihan Anda. Ini membantu mengidentifikasi pekerjaan Anda di Konsol AWS Manajemen.
- **model_type:** Varian model Amazon Nova untuk digunakan. Opsi yang tersedia adalah `amazon.nova-2-lite-v1:0:256k`.
- **model_name_or_path:** Jalur ke model dasar yang akan digunakan untuk pelatihan Anda. Opsi yang tersedia adalah `nova-lite-2/prod`, atau jalur S3 untuk pos pemeriksaan pasca-pelatihan (`.`).
`s3://customer-escrow-bucket-unique_id/training_run_name`
- **replika:** Jumlah instance komputasi yang digunakan untuk pelatihan terdistribusi. Nilai yang tersedia bervariasi berdasarkan model yang Anda pilih. Amazon Nova Lite 2.0 mendukung replika 4, 8, 16, atau 32.
- **data_s3_path:** Lokasi S3 dari dataset pelatihan, yang merupakan file JSONL. File ini harus berada di AWS akun dan Wilayah yang sama dengan cluster. Semua lokasi S3 yang disediakan harus berada di akun dan Wilayah yang sama.
- **validation_data_s3_path:** (Opsional) Lokasi S3 dari dataset validasi, yang merupakan file JSONL. File ini harus berada di akun dan wilayah yang sama dengan cluster. Semua lokasi S3 yang disediakan harus berada di akun dan Wilayah yang sama.
- **output_s3_path:** Lokasi S3 tempat manifes dan log disimpan. TensorBoard Semua lokasi S3 yang disediakan harus berada di AWS akun dan AWS Wilayah yang sama.
- **mlflow_tracking_uri:** ARN Aplikasi yang akan digunakan untuk logging MLFlow MLFlow
- **mlflow_experiment_name:** nama percobaan MLFlow
- **mlflow_run_name:** jalankan nama MLFlow

Konfigurasi Pelatihan

- `max_length`: Panjang urutan maksimum dalam token. Ini menentukan ukuran jendela konteks untuk pelatihan. Nilai maksimum yang didukung adalah 8192 token untuk CPT.

Urutan yang lebih panjang akan meningkatkan efisiensi pelatihan dengan mengorbankan peningkatan kebutuhan memori. Kami menyarankan Anda mencocokkan parameter `max_length` dengan distribusi data Anda.

- `global_batch_size`: Jumlah total sampel pelatihan yang diproses bersama dalam satu pass maju atau mundur di semua perangkat dan pekerja.

Nilai ini mengalikan ukuran batch per perangkat dan jumlah perangkat. Ini mempengaruhi stabilitas pelatihan dan throughput. Kami menyarankan Anda memulai dengan ukuran batch yang pas dengan nyaman di dalam memori Anda dan meningkatkan skala dari sana. Untuk data spesifik domain, batch yang lebih besar mungkin gradien yang terlalu halus.

Pengaturan Pelatih

- `max_steps`: Jumlah langkah pelatihan yang harus dijalankan. Setiap langkah akan melatih model dengan `global_batch_size` tidak. elemen

Pengaturan Model

- `hidden_dropout`: Probabilitas menjatuhkan output status tersembunyi. Tingkatkan nilai ini sekitar 0,0-0,2 untuk mengurangi overfitting pada kumpulan data yang lebih kecil. Nilai yang valid adalah antara 0-1, inklusif.
- `attention_dropout`: Probabilitas penurunan bobot perhatian. Parameter ini dapat membantu generalisasi. Nilai yang valid adalah antara 0-1, inklusif.

Konfigurasi Pengoptimal

- `lr`: Tingkat pembelajaran, yang mengontrol ukuran langkah selama pengoptimalan. Kami merekomendasikan nilai antara $1e-6$ - $1e-4$ untuk kinerja yang baik. Nilai yang valid adalah antara 0-1, inklusif.
- `nama`: Algoritma pengoptimal. Saat ini, hanya `distributed_fused_adam` didukung.

- `weight_decay`: Kekuatan regularisasi L2. Nilai yang lebih tinggi (antara 0,01-0,1) meningkatkan regularisasi.
- `warmup_steps`: Jumlah langkah untuk meningkatkan tingkat pembelajaran secara bertahap. Ini meningkatkan stabilitas pelatihan. Nilai yang valid adalah antara 1-20, inklusif.
- `min_lr`: Tingkat pembelajaran minimum pada akhir pembusukan. Nilai yang valid antara 0-1, inklusif, tetapi harus kurang dari tingkat pembelajaran.

Penyetelan halus yang diawasi (SFT)

Proses pelatihan SFT terdiri dari dua tahap utama:

- **Persiapan Data**: Ikuti pedoman yang ditetapkan untuk membuat, membersihkan, atau memformat ulang kumpulan data ke dalam struktur yang diperlukan. Pastikan bahwa input, output, dan informasi tambahan (seperti jejak penalaran atau metadata) diselaraskan dan diformat dengan benar.
- **Konfigurasi Pelatihan**: Tentukan bagaimana model akan dilatih. Saat menggunakan, konfigurasi ini ditulis dalam file resep YAMB yang mencakup:
 - Jalur sumber data (kumpulan data pelatihan dan validasi)
 - Hiperparameter kunci (zaman, tingkat pembelajaran, ukuran batch)
 - Komponen opsional (parameter pelatihan terdistribusi, dll)

Perbandingan dan Seleksi Model Nova

Amazon Nova 2.0 adalah model yang dilatih pada dataset yang lebih besar dan lebih beragam daripada Amazon Nova 1.0. Perbaikan utama meliputi:

- Kemampuan penalaran yang ditingkatkan dengan dukungan mode penalaran eksplisit
- Kinerja multibahasa yang lebih luas di seluruh bahasa tambahan
- Peningkatan kinerja pada tugas-tugas kompleks termasuk pengkodean dan penggunaan alat
- Penanganan konteks yang diperluas dengan akurasi dan stabilitas yang lebih baik pada panjang konteks yang lebih panjang

Kapan Menggunakan Nova 1.0 vs Nova 2.0

Pilih Amazon Nova 2.0 saat:

- Kinerja superior dengan kemampuan penalaran tingkat lanjut diperlukan
- Dukungan multibahasa atau penanganan tugas yang kompleks diperlukan
- Hasil yang lebih baik pada pengkodean, panggilan alat, atau tugas analitis diperlukan

SFT pada Nova 2.0

Amazon Nova Lite 2.0 menghadirkan kemampuan yang disempurnakan untuk fine-tuning yang diawasi, termasuk mode penalaran lanjutan, pemahaman multimodal yang ditingkatkan, dan penanganan konteks yang diperluas. SFT di Nova 2.0 memungkinkan Anda untuk menyesuaikan kemampuan canggih ini dengan kasus penggunaan spesifik Anda sambil mempertahankan kinerja superior model pada tugas-tugas kompleks.

Fitur utama SFT pada Nova 2.0 meliputi:

- Dukungan mode penalaran: Latih model untuk menghasilkan jejak penalaran eksplisit sebelum jawaban akhir untuk kemampuan analitis yang ditingkatkan.
- Pelatihan multimodal tingkat lanjut: Menyesuaikan pemahaman dokumen (PDF), pemahaman video, dan tugas berbasis gambar dengan akurasi yang ditingkatkan.
- Kemampuan pemanggilan alat: Latih model untuk secara efektif menggunakan alat eksternal dan panggilan fungsi untuk alur kerja yang kompleks.
- Dukungan konteks yang diperluas: Manfaatkan jendela konteks yang lebih panjang dengan stabilitas dan akurasi yang lebih baik untuk aplikasi intensif dokumen.

Note

Untuk informasi lebih lanjut tentang gambar wadah mana, atau contoh resep yang akan digunakan, buka [resep Amazon Nova](#).

Topik

- [Pemilihan Mode Penalaran \(Hanya Nova 2.0\)](#)
- [Alat memanggil format data](#)
- [Format data pemahaman dokumen](#)
- [Pemahaman Video untuk SFT](#)
- [Instruksi Unggah Data](#)

- [Membuat Fine-Tuning Job](#)
- [Parameter Penyetelan SFT](#)
- [Panduan Hyperparameter](#)

Contoh resep SFT

Di bawah ini adalah contoh resep untuk SFT. Anda dapat menemukan resep ini dan lainnya di repositori [resep](#).

```
run:
  name: my-full-rank-sft-run
  model_type: amazon.nova-2-lite-v1:0:256k
  model_name_or_path: nova-lite-2/prod
  data_s3_path: s3://my-bucket-name/train.jsonl # only and not compatible with
SageMaker Training Jobs
  replicas: 4 # Number of compute instances for
training, allowed values are 4, 8, 16, 32
  output_s3_path: s3://my-bucket-name/outputs/ # Output artifact path (HyperPod job-
specific; not compatible with standard SageMaker Training Jobs)
  mlflow_tracking_uri: "" # Required for MLFlow
  mlflow_experiment_name: "my-full-rank-sft-experiment" # Optional for MLFlow. Note:
leave this field non-empty
  mlflow_run_name: "my-full-rank-sft-run" # Optional for MLFlow. Note: leave
this field non-empty

training_config:
  max_steps: 100 # Maximum training steps. Minimal is 4.
  save_steps: ${oc.select:training_config.max_steps} # How many training steps the
checkpoint will be saved
  save_top_k: 5 # Keep top K best checkpoints. Note supported only
for jobs. Minimal is 1.
  max_length: 32768 # Sequence length (options: 8192, 16384, 32768
[default], 65536)
  global_batch_size: 32 # Global batch size (options: 32, 64, 128)
  reasoning_enabled: true # If data has reasoningContent, set to true;
otherwise False

  lr_scheduler:
    warmup_steps: 15 # Learning rate warmup steps. Recommend 15% of
max_steps
    min_lr: 1e-6 # Minimum learning rate, must be between 0.0 and
1.0
```

```
optim_config:                # Optimizer settings
  lr: 1e-5                    # Learning rate, must be between 0.0 and 1.0
  weight_decay: 0.0          # L2 regularization strength, must be between 0.0
and 1.0
  adam_beta1: 0.9             # Exponential decay rate for first-moment
estimates
  adam_beta2: 0.95           # Exponential decay rate for second-moment
estimates

peft:                         # Parameter-efficient fine-tuning (LoRA)
  peft_scheme: "null"        # Disable LoRA for PEFT
```

Pemilihan Mode Penalaran (Hanya Nova 2.0)

Amazon Nova 2.0 mendukung mode penalaran untuk kemampuan analitis yang ditingkatkan:

- Mode Penalaran (diaktifkan):
 - Atur `reasoning_enabled: true` dalam konfigurasi pelatihan
 - Model melatih untuk menghasilkan jejak penalaran sebelum jawaban akhir
 - Meningkatkan kinerja pada tugas penalaran yang kompleks
- Mode Non-Penalaran (dinonaktifkan):
 - Mengatur `reasoning_enabled: false` atau menghilangkan parameter (default)
 - SFT standar tanpa alasan eksplisit
 - Cocokkan untuk tugas yang tidak mendapat manfaat dari step-by-step penalaran

Note

- Ketika penalaran diaktifkan, ia beroperasi pada upaya penalaran yang tinggi. Tidak ada opsi penalaran rendah untuk SFT.
- Konten penalaran multimodal tidak didukung untuk SFT. Mode penalaran berlaku untuk input teks saja.

Menggunakan mode penalaran dengan kumpulan data non-penalaran

Melatih Amazon Nova pada kumpulan data non-penalaran dengan `reasoning_enabled: true` diizinkan. Namun, hal itu dapat menyebabkan model kehilangan kemampuan penalarannya, karena Amazon Nova terutama belajar untuk menghasilkan respons yang disajikan dalam data tanpa menerapkan penalaran.

Jika melatih Amazon Nova pada kumpulan data non-penalaran tetapi masih ingin menggunakan penalaran selama inferensi:

1. Nonaktifkan penalaran selama pelatihan () `reasoning_enabled: false`
2. Aktifkan penalaran nanti selama inferensi

Meskipun pendekatan ini memungkinkan penalaran pada waktu inferensi, itu tidak menjamin peningkatan kinerja dibandingkan dengan inferensi tanpa penalaran.

Praktik terbaik: Aktifkan penalaran untuk pelatihan dan inferensi saat menggunakan kumpulan data penalaran, dan nonaktifkan keduanya saat menggunakan kumpulan data non-penalaran.

Note

Untuk informasi lebih lanjut tentang gambar wadah mana, atau contoh resep yang akan digunakan, buka [resep Amazon Nova](#).

Alat memanggil format data

SFT mendukung model pelatihan untuk menggunakan alat (panggilan fungsi). Di bawah ini adalah contoh format input untuk pemanggilan alat:

Masukan sampel:

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

```

Pertimbangan penting untuk data panggilan alat:

- ToolUse harus muncul di asisten giliran saja
- ToolResult harus muncul di giliran pengguna saja
- ToolResult harus berupa teks atau JSON saja; modalitas lain saat ini tidak didukung untuk model Amazon Nova
- InputSchema dalam ToolSpec harus berupa objek Skema JSON yang valid
- Masing-masing ToolResult harus mereferensikan yang valid toolUseId dari asisten sebelumnya ToolUse, dengan masing-masing toolUseId digunakan tepat sekali per percakapan

 Note

Untuk informasi lebih lanjut tentang gambar wadah mana, atau contoh resep yang akan digunakan, buka [resep Amazon Nova](#).

Format data pemahaman dokumen

SFT mendukung model pelatihan tentang tugas pemahaman dokumen. Di bawah ini adalah contoh format input:

Masukan sampel

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

Pertimbangan penting untuk pemahaman dokumen:

- Hanya file PDF yang didukung
- Ukuran dokumen maksimum adalah 10 MB
- Sampel dapat berisi dokumen dan teks, tetapi tidak dapat mencampur dokumen dengan modalitas lain (seperti gambar atau video)

Note

Untuk informasi lebih lanjut tentang gambar wadah mana, atau contoh resep yang akan digunakan, buka [resep Amazon Nova](#).

Pemahaman Video untuk SFT

SFT mendukung model fine-tuning untuk tugas pemahaman video. Di bawah ini adalah contoh format input:

Masukan sampel

```
{  
  "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"
        }
      ]
    }
  ]
}

```

Pertimbangan penting untuk pemahaman video:

- Video bisa maksimal 50 MB
- Video bisa berdurasi hingga 15 menit

- Hanya satu video yang diizinkan per sampel; beberapa video dalam sampel yang sama tidak didukung
- Sampel dapat berisi video dan teks, tetapi tidak dapat mencampur video dengan modalitas lain (seperti gambar atau dokumen)

Note

Untuk informasi lebih lanjut tentang gambar wadah mana, atau contoh resep yang akan digunakan, buka [resep Amazon Nova](#).

Instruksi Unggah Data

Unggah kumpulan data pelatihan dan validasi ke bucket S3. Tentukan lokasi ini di run blok resep:

```
## Run config
run:
  ...
  data_s3_path: "s3://<bucket-name>/<training-directory>/<training-file>.jsonl"
```

Catatan: Ganti<bucket-name>,<training-directory>,<validation-directory>,<training-file>, dan <validation-file> dengan jalur S3 yang sebenarnya.

Catatan: Kumpulan data validasi saat ini tidak didukung untuk SFT dengan Amazon Nova 2.0. Jika dataset validasi disediakan, itu akan diabaikan.

Membuat Fine-Tuning Job

Tentukan model dasar menggunakan `model_type` dan `model_name_or_path` bidang di run blok:

```
## Run config
run:
  ...
  model_type: amazon.nova-2-lite-v1:0:256k
  model_name_or_path: nova-lite-2/prod
  ...
```


Parameter Penyetelan SFT

Parameter yang tersedia untuk penyetelan dengan SFT meliputi:

Jalankan Konfigurasi

- **nama:** Nama deskriptif untuk pekerjaan pelatihan Anda. Ini membantu mengidentifikasi pekerjaan Anda di Konsol AWS Manajemen.
- **model_type:** Varian model Amazon Nova untuk digunakan. Opsi yang tersedia adalah `amazon.nova-2-lite-v1:0:256k`.
- **model_name_or_path:** Jalur ke model dasar yang akan digunakan untuk pelatihan Anda. Opsi yang tersedia adalah `nova-lite-2/prod`, atau jalur S3 untuk pos pemeriksaan pasca-pelatihan (`s3://customer-escrow-bucket-unique_id/training_run_name`).
- **replika:** Jumlah instance komputasi yang digunakan untuk pelatihan terdistribusi. Nilai yang tersedia bervariasi berdasarkan model yang Anda pilih. Amazon Nova Lite 2.0 mendukung replika 4, 8, 16, atau 32.
- **data_s3_path:** Lokasi S3 dari dataset pelatihan, yang merupakan file JSONL. File ini harus berada di AWS akun dan Wilayah yang sama dengan cluster. Semua lokasi S3 yang disediakan harus berada di akun dan Wilayah yang sama.
- **validation_data_s3_path:** (Opsional) Lokasi S3 dari dataset validasi, yang merupakan file JSONL. File ini harus berada di akun dan wilayah yang sama dengan cluster. Semua lokasi S3 yang disediakan harus berada di akun dan Wilayah yang sama.
- **output_s3_path:** Lokasi S3 tempat manifes dan log disimpan. TensorBoard Semua lokasi S3 yang disediakan harus berada di AWS akun dan AWS Wilayah yang sama.
- **mlflow_tracking_uri:** ARN Aplikasi yang akan digunakan untuk logging. MLFlow MLFlow
- **mlflow_experiment_name:** nama percobaan. MLFlow
- **mlflow_run_name:** jalankan nama. MLFlow

Konfigurasi Pelatihan

- **max_steps:** Jumlah langkah pelatihan yang harus dijalankan. Setiap langkah akan melatih model dengan `global_batch_size` jumlah elemen.
- **save_steps:** Frekuensi (dalam langkah-langkah) untuk menyimpan pos pemeriksaan model selama pelatihan.

- `save_top_k`: Jumlah maksimum pos pemeriksaan terbaik untuk dipertahankan berdasarkan metrik validasi.
- `max_length`: Panjang urutan maksimum dalam token. Ini menentukan ukuran jendela konteks untuk pelatihan. Nilai maksimum yang didukung adalah 32768 token untuk SFT.

Urutan yang lebih panjang akan meningkatkan efisiensi pelatihan dengan mengorbankan peningkatan kebutuhan memori. Kami menyarankan Anda mencocokkan parameter `max_length` dengan distribusi data Anda.

- `global_batch_size`: Jumlah total sampel pelatihan yang diproses bersama dalam satu pass maju atau mundur di semua perangkat dan pekerja.

Nilai ini mengalikan ukuran batch per perangkat dan jumlah perangkat. Ini mempengaruhi stabilitas pelatihan dan throughput. Kami menyarankan Anda memulai dengan ukuran batch yang pas dengan nyaman di dalam memori Anda dan meningkatkan skala dari sana. Untuk data spesifik domain, batch yang lebih besar mungkin gradien yang terlalu halus.

- `reasoning_enabled`: Boolean flag untuk mengaktifkan kemampuan penalaran selama pelatihan.

Penjadwal Tingkat Pembelajaran

- `warmup_steps`: Jumlah langkah untuk meningkatkan tingkat pembelajaran secara bertahap. Ini meningkatkan stabilitas pelatihan.
- `min_lr`: Tingkat pembelajaran minimum pada akhir pembusukan. Nilai yang valid antara 0-1, inklusif, tetapi harus kurang dari tingkat pembelajaran.

Konfigurasi Pengoptimal

- `lr`: Tingkat pembelajaran, yang mengontrol ukuran langkah selama pengoptimalan. Kami merekomendasikan nilai antara $1e-6$ - $1e-4$ untuk kinerja yang baik. Nilai yang valid adalah antara 0-1, inklusif.
- `weight_decay`: Kekuatan regularisasi L2. Nilai yang lebih tinggi (antara 0,01-0,1) meningkatkan regularisasi.
- `adam_beta1`: Tingkat peluruhan eksponensial untuk perkiraan momen pertama di pengoptimal Adam. Defaultnya adalah 0,9.
- `adam_beta2`: Tingkat peluruhan eksponensial untuk perkiraan momen kedua dalam pengoptimal Adam. Defaultnya adalah 0,95.

Konfigurasi PEFT

- `peft_scheme`: Skema fine-tuning hemat parameter untuk digunakan. Pilihannya adalah `'null'` untuk fine-tuning peringkat penuh atau `lora` untuk fine-tuning berbasis Lora.

LoRa Tuning (ketika `peft_scheme` adalah `'lora'`)

- `alpha`: Parameter penskalaan LoRa. Mengontrol besarnya adaptasi peringkat rendah. Nilai tipikal berkisar dari 8 hingga 128.
- `lora_plus_lr_ratio`: Rasio tingkat pembelajaran untuk optimasi LoRa+. Pengganda ini menyesuaikan tingkat pembelajaran khusus untuk parameter LoRa.

Panduan Hyperparameter

Gunakan hiperparameter yang direkomendasikan berikut berdasarkan pendekatan pelatihan:

Pelatihan Peringkat Penuh

- Zaman: 1
- Tingkat pembelajaran (`lr`): $1e-5$
- Tingkat pembelajaran minimum (`min_lr`): $1e-6$

LoRa (Adaptasi Peringkat Rendah)

- Zaman: 2
- Tingkat pembelajaran (`lr`): $5e-5$
- Tingkat pembelajaran minimum (`min_lr`): $1e-6$

Catatan: Sesuaikan nilai-nilai ini berdasarkan ukuran dataset dan kinerja validasi. Pantau metrik pelatihan untuk mencegah overfitting.

Penguatan Fine-Tuning (RFT) aktif SageMaker HyperPod

Reinforcement Fine-Tuning (RFT) adalah teknik pembelajaran mesin yang meningkatkan kinerja model melalui sinyal umpan balik — skor terukur atau penghargaan yang menunjukkan kualitas

respons — daripada pengawasan langsung dengan jawaban yang benar dan tepat. Tidak seperti fine-tuning tradisional yang diawasi yang belajar dari pasangan input-output, RFT menggunakan fungsi hadiah untuk mengevaluasi respons model dan secara iteratif mengoptimalkan model untuk memaksimalkan penghargaan ini.

Pendekatan ini sangat efektif untuk tugas-tugas di mana mendefinisikan output yang benar secara tepat menantang, tetapi Anda dapat mengukur kualitas respons dengan andal. RFT memungkinkan model untuk mempelajari perilaku dan preferensi yang kompleks melalui uji coba dan umpan balik, menjadikannya ideal untuk aplikasi yang membutuhkan pengambilan keputusan bernuansa, pemecahan masalah yang kreatif, atau kepatuhan terhadap kriteria kualitas tertentu yang dapat dievaluasi secara terprogram.

Kapan menggunakan RFT

Gunakan RFT ketika Anda dapat menentukan kriteria keberhasilan yang jelas dan terukur tetapi berjuang untuk memberikan output yang tepat untuk pelatihan. Ini ideal untuk tugas-tugas di mana kualitas bersifat subjektif atau multifase—seperti penulisan kreatif, pengoptimalan kode, atau penalaran kompleks—di mana ada beberapa solusi yang valid tetapi beberapa jelas lebih baik daripada yang lain.

RFT bekerja paling baik ketika Anda memiliki yang berikut:

- Fungsi hadiah yang andal yang dapat mengevaluasi output model secara terprogram
- Perlu menyelaraskan perilaku model dengan preferensi atau kendala tertentu
- Situasi di mana fine-tuning tradisional yang diawasi gagal karena mengumpulkan contoh berlabel berkualitas tinggi mahal atau tidak praktis

Pertimbangkan RFT untuk aplikasi yang membutuhkan perbaikan berulang, personalisasi, atau kepatuhan terhadap aturan bisnis kompleks yang dapat dikodekan sebagai sinyal hadiah.

RFT apa yang paling cocok untuk

RFT unggul dalam domain di mana kualitas output dapat diukur secara objektif tetapi respons optimal sulit untuk didefinisikan di muka:

- Pemecahan masalah matematis: Kebenaran yang dapat diverifikasi dengan beberapa jalur solusi
- Pembuatan dan pengoptimalan kode: Hasil eksekusi dan metrik kinerja yang dapat diuji
- Tugas penalaran ilmiah: Konsistensi logis dan akurasi faktual

- Analisis data terstruktur: Output yang dapat diverifikasi secara terprogram
- Penalaran multi-langkah: Tugas yang membutuhkan perkembangan logis step-by-step
- Penggunaan alat dan panggilan API: Keberhasilan dapat diukur dengan hasil eksekusi
- Alur kerja yang kompleks: Kepatuhan terhadap kendala dan aturan bisnis tertentu

RFT bekerja sangat baik ketika Anda perlu menyeimbangkan beberapa tujuan yang bersaing seperti akurasi, efisiensi, dan gaya.

Kapan menggunakan mode penalaran untuk pelatihan RFT

Amazon Nova 2.0 mendukung mode penalaran selama pelatihan RFT. Mode berikut tersedia:

- none: Tidak ada alasan (hilangkan bidang `reasing_effort`)
- rendah: Overhead penalaran minimal
- tinggi: Kemampuan penalaran maksimum (default saat `reasing_effort` ditentukan)

 Note

Tidak ada opsi medium untuk RFT. Jika bidang `reasing_effort` tidak ada dalam konfigurasi Anda, penalaran akan dinonaktifkan.

Gunakan penalaran tinggi untuk hal-hal berikut:

- Tugas analitis yang kompleks
- Pemecahan masalah matematika
- Pengurangan logis multi-langkah
- Tugas di mana step-by-step berpikir menambah nilai

Gunakan none (hilangkan `reasing_effort`) atau alasan rendah untuk hal berikut:

- Pertanyaan faktual sederhana
- Klasifikasi langsung
- Optimalisasi kecepatan dan biaya
- Menjawab pertanyaan langsung

⚠ Important

Mode penalaran yang lebih tinggi meningkatkan waktu dan biaya pelatihan, latensi inferensi dan biaya, tetapi juga meningkatkan kemampuan model untuk tugas penalaran yang kompleks.

Model yang didukung

RFT onSageMaker HyperPod mendukung Amazon Nova Lite 2.0 (amazon.nova-2-lite-v 1:0:256 k).

Langkah-langkah utama

Proses RFT melibatkan empat fase utama:

- Menerapkan evaluator: Buat fungsi hadiah untuk menilai respons model secara terprogram berdasarkan kriteria kualitas Anda.
- Permintaan pengunggahan: Mempersiapkan dan mengunggah data pelatihan dalam format percakapan yang ditentukan dengan data referensi untuk evaluasi.
- Memulai pekerjaan: Luncurkan proses fine-tuning penguatan dengan parameter yang Anda konfigurasi.
- Pemantauan: Lacak kemajuan pelatihan melalui dasbor metrik untuk memastikan model belajar secara efektif.

Setiap langkah dibangun di atas langkah sebelumnya, dengan evaluator berfungsi sebagai fondasi yang memandu seluruh proses pelatihan dengan memberikan sinyal umpan balik yang konsisten.

Topik

- [RFT pada Nova 2.0](#)

RFT pada Nova 2.0

Data pelatihan RFT mengikuti format percakapan OpenAI. Setiap contoh pelatihan adalah objek JSON yang berisi pesan, jawaban referensi, dan definisi alat opsional. Bagian ini memberikan panduan tentang mempersiapkan data pelatihan yang efektif untuk RFT di Nova 2.0.

Topik

- [Format dan struktur data](#)

- [Deskripsi bidang](#)
- [Panduan Hyperparameter](#)
- [Properti tambahan](#)
- [Rekomendasi ukuran set data](#)
- [Karakteristik data pelatihan yang efektif](#)
- [Memantau pelatihan RFT](#)

Format dan struktur data

Setiap contoh pelatihan adalah objek JSON yang berisi berikut ini:

- pesan: Array giliran percakapan menggunakan sistem, pengguna, dan peran asisten opsional
- reference_answer: Output yang diharapkan atau kriteria evaluasi untuk perhitungan hadiah
- alat (opsional): Array definisi fungsi yang tersedia untuk model
- id (opsional): Pengidentifikasi unik untuk pelacakan dan deduplikasi

Setiap contoh harus pada satu baris dalam file JSONL Anda, dengan satu objek JSON per baris.

Contoh 1: Masalah kimia

Contoh berikut menunjukkan masalah kimia dengan jawaban referensi yang mengandung nilai kebenaran dasar:

```
{
  "id": "chem-001",
  "messages": [
    {
      "role": "system",
      "content": "You are a helpful chemistry assistant"
    },
    {
      "role": "user",
      "content": "Predict hydrogen bond donors and acceptors for this SMILES:
CCN(CC)CCC(=O)c1sc(N)nc1C"
    }
  ],
  "reference_answer": {
    "donor_bond_counts": 2,
    "acceptor_bond_counts": 4,
```

```
"explanation": "Calculated using Lipinski's rule of five: N-H groups (2 donors), N
and 0 atoms with lone pairs (4 acceptors)"
}
}
```

Note

Reference_answer berisi nilai kebenaran dasar yang dihitung menggunakan aturan khusus domain. Fungsi hadiah Anda membandingkan nilai prediksi model dengan nilai referensi ini untuk menghitung skor hadiah.

Contoh 2: Masalah matematika

Contoh berikut menunjukkan masalah matematika dengan langkah-langkah solusi:

```
{
  "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": [" $2x = 13 - 5$ ", " $2x = 8$ ", " $x = 4$ "]
  }
}
```

Contoh 3: Penggunaan alat

Contoh berikut menunjukkan penggunaan alat dengan perilaku yang diharapkan:

```
{
  "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"
}
```

Deskripsi bidang

Bidang	Deskripsi	Catatan tambahan	Diperlukan
id	Pengidentifikasi unik untuk contoh RFT ini	String (misalnya , “sample-001”). Berguna untuk melacak dan deduplikasi.	Tidak
pesan	Daftar pesan obrolan yang diurutkan yang menentukan prompt dan konteks	Array objek. Model melihat mereka secara berurutan . Biasanya dimulai dengan pesan sistem, lalu pengguna.	Ya
pesan [].role	Siapa yang berbicara dalam pesan	Nilai umum: “sistem”, “pengguna” (terkadang “asisten” dalam konteks lain)	Tidak
pesan [].content	Isi teks pesan	Tali polos. Untuk sistem itu instruksi, untuk pengguna itu tugas atau input.	Tidak
alat	Spesifikasi alat tersedia untuk model selama contoh ini	Array. Setiap item mendefinisikan antarmuka alat dan metadata. Jenis mungkin termasuk “fungsi” atau “internal”.	Tidak
referensi_jawaban	Output model yang diharapkan untuk contoh ini	String atau objek tergantung pada tugas. Digunakan	Tidak

Bidang	Deskripsi	Catatan tambahan	Diperlukan
		sebagai target untuk evaluasi atau pelatihan.	

Note

Setiap bidang kustom tambahan (misalnya, `task_id`, `difficult level`, `context_data`) tidak divalidasi dan akan diteruskan ke fungsi reward Anda sebagai metadata.

Panduan Hyperparameter

Gunakan hiperparameter yang direkomendasikan berikut berdasarkan pendekatan pelatihan Anda:

Umum:

- Zaman: 1
- Tingkat pembelajaran (lr): $1e-7$
- Jumlah generasi: 8
- Token baru maks: 8192
- Ukuran Batch: 256

LoRa (Adaptasi Peringkat Rendah):

- Ranking LoRa: 32

Note

Sesuaikan nilai-nilai ini berdasarkan ukuran set data dan kinerja validasi Anda. Pantau metrik pelatihan untuk mencegah overfitting.

Properti tambahan

Pengaturan “additionalProperties”: true memungkinkan Anda menyertakan bidang khusus di luar persyaratan skema inti, memberikan fleksibilitas untuk menambahkan data apa pun yang dibutuhkan fungsi hadiah Anda untuk evaluasi yang tepat.

Bidang tambahan umum

Anda dapat menyertakan jenis bidang tambahan berikut:

Metadata:

- `task_id`: Pengidentifikasi unik untuk melacak
- `complexity_level`: Indikator kompleksitas masalah
- `domain`: Area subjek atau kategori
- `expected_reasoning_steps`: Jumlah langkah dalam solusi

Kriteria evaluasi:

- `evaluation_criteria`: Rubrik penilaian khusus
- `custom_scoring_weights`: Kepentingan relatif dari berbagai aspek
- `context_data`: Informasi latar belakang untuk masalah
- `external_references`: Tautan ke dokumentasi atau sumber daya yang relevan

Contoh dengan properti tambahan

Contoh berikut mencakup bidang metadata kustom:

```
{
  "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
}
```

Rekomendasi ukuran set data

Titik awal

Mulailah dengan ukuran set data minimum berikut:

- Minimal 100 contoh pelatihan
- Minimal 100 contoh evaluasi

Prioritaskan data input berkualitas tinggi dan fungsi hadiah yang andal yang dijalankan secara konsisten pada respons model.

Pendekatan evaluasi-pertama

Sebelum berinvestasi dalam pelatihan RFT skala besar, evaluasi kinerja dasar model Anda:

- Kinerja tinggi (hadiah lebih dari 95%): RFT mungkin tidak perlu — model Anda sudah berkinerja baik
- Kinerja yang sangat buruk (hadiah 0%): Beralih ke SFT terlebih dahulu untuk membangun kemampuan dasar
- Kinerja sedang: RFT kemungkinan sesuai

Pendekatan evaluasi pertama ini memastikan fungsi reward Anda bebas bug dan menentukan apakah RFT adalah metode yang tepat untuk kasus penggunaan Anda. Mulai dari yang kecil memungkinkan Anda merasa nyaman dengan alur kerja RFT, mengidentifikasi dan memperbaiki masalah lebih awal, memvalidasi pendekatan Anda sebelum meningkatkan, dan menguji keandalan fungsi hadiah. Setelah divalidasi, Anda dapat memperluas ke kumpulan data yang lebih besar untuk lebih meningkatkan kinerja.

Karakteristik data pelatihan yang efektif

Kejelasan dan konsistensi

Contoh RFT yang baik membutuhkan data input yang jelas dan tidak ambigu yang memungkinkan perhitungan hadiah yang akurat di berbagai output model. Hindari kebisingan dalam data Anda, termasuk:

- Pemformatan yang tidak konsisten
- Label atau instruksi yang kontradiktif
- Permintaan ambigu
- Jawaban referensi yang bertentangan

Ambiguitas apa pun akan menyesatkan proses pelatihan dan menyebabkan model mempelajari perilaku yang tidak diinginkan.

Keanekaragaman

Dataset Anda harus menangkap keragaman penuh kasus penggunaan produksi untuk memastikan kinerja dunia nyata yang kuat. Termasuk:

- Berbagai jenis masalah dan tingkat kesulitan
- Format input dan kasus tepi yang berbeda
- Sampel representatif dari semua skenario yang diharapkan

Keragaman ini membantu mencegah overfitting dan memastikan model menangani input yang tidak dikenal dengan anggun.

Pertimbangan fungsi penghargaan

Rancang fungsi hadiah Anda untuk pelatihan yang efisien:

- Jalankan dalam hitungan detik (bukan menit)
- Paralelisasi secara efektif dengan Lambda
- Kembalikan skor yang konsisten dan andal
- Tangani berbagai jenis keluaran model dengan anggun

Fungsi hadiah yang cepat dan dapat diskalakan memungkinkan iterasi cepat dan eksperimen hemat biaya dalam skala besar.

Memantau pelatihan RFT

Pantau metrik utama selama pelatihan untuk memastikan pembelajaran yang efektif dan mengidentifikasi potensi masalah sejak dini.

Topik

- [Metrik kunci untuk dilacak](#)
- [Evaluasi setelah RFT](#)
- [Menggunakan model yang disetel dengan baik](#)
- [Keterbatasan dan praktik terbaik](#)
- [Pemecahan masalah](#)

Metrik kunci untuk dilacak

Pantau metrik berikut yang digunakan MIFlow selama pelatihan:

Metrik hadiah:

- Skor hadiah rata-rata: Kualitas keseluruhan respons model (harus meningkat seiring waktu)
- Distribusi hadiah: Persentase tanggapan yang menerima hadiah tinggi, sedang, dan rendah
- Hadiah pelatihan vs. validasi: Bandingkan untuk mendeteksi overfitting

Metrik pelatihan:

- Pembaruan kebijakan: Jumlah pembaruan bobot yang berhasil
- Tingkat penyelesaian peluncuran: Persentase sampel yang berhasil dievaluasi

Mengenai pola:

- Imbalan dataran tinggi (menunjukkan pembelajaran yang buruk)
- Hadiah validasi turun saat hadiah pelatihan meningkat (overfitting)
- Varians hadiah meningkat secara signifikan dari waktu ke waktu (ketidakstabilan)
- Persentase kesalahan fungsi hadiah yang tinggi (masalah implementasi)

Kapan harus menghentikan pelatihan:

- Metrik kinerja target tercapai
- Imbalan dataran tinggi dan tidak lagi membaik
- Kinerja validasi menurun (overfitting terdeteksi)
- Anggaran pelatihan maksimum tercapai

Evaluasi setelah RFT

Setelah pelatihan selesai, evaluasi model yang disetel dengan baik untuk menilai peningkatan kinerja:

- Jalankan pekerjaan evaluasi RFT: Gunakan pos pemeriksaan dari pelatihan RFT Anda sebagai model
- Bandingkan dengan baseline: Evaluasi model dasar dan model yang disetel dengan baik pada set pengujian yang sama
- Analisis metrik: Tinjau metrik khusus tugas (akurasi, skor hadiah, dll.)
- Melakukan tinjauan kualitatif: Periksa secara manual keluaran sampel untuk kualitas

Untuk prosedur evaluasi terperinci, lihat bagian Evaluasi.

Menggunakan model yang disetel dengan baik

Mengakses pos pemeriksaan:

Setelah pelatihan selesai, cari pos pemeriksaan Anda:

1. Arahkan ke Anda `output_path` di S3
2. Unduh dan ekstrak `output.tar.gz`
3. Terbuka `manifest.json`
4. Salin `checkpoint_s3_bucket` nilainya

Menerapkan untuk inferensi:

Gunakan jalur pos pemeriksaan S3 untuk inferensi atau pelatihan lebih lanjut:

```
run:
```



```
model_type: amazon.nova-2-lite-v1:0:256k
model_name_or_path: "s3://customer-escrow-<account-number>-smtj-<unique-
identifier>/<job-name>"
```

Untuk instruksi penyebaran dan inferensi, lihat bagian Inferensi.

Keterbatasan dan praktik terbaik

Keterbatasan saat ini:

Pembatasan beta:

- Perlu membuat grup RIG baru untuk RFT. Batasan ini akan diselesaikan oleh GA.
- Persyaratan tipe instans: Hanya instans P5 yang didukung (minimal 8x p5.48xLarge). Segera Hadir: Dukungan untuk jenis instans yang lebih kecil (ETA: pertengahan Januari 2025).

Keterbatasan fungsional:

- Batas waktu Lambda 15 menit: Fungsi hadiah harus selesai dalam 15 menit
- Hanya satu putaran: Percakapan multi-putaran tidak didukung
- Kumpulan data validasi: Tidak didukung selama pelatihan. Gunakan pekerjaan evaluasi terpisah untuk menilai kemajuan pelatihan.

Pertimbangan pelatihan:

- Skenario hadiah rendah: Mungkin kesulitan ketika kurang dari 5% contoh menerima hadiah positif - pertimbangkan SFT terlebih dahulu
- Persyaratan data: Membutuhkan keragaman yang cukup untuk belajar secara efektif
- Biaya komputasi: Lebih mahal daripada fine-tuning yang diawasi

Nova Forge menghapus beberapa keterbatasan ini:

- Mendukung percakapan multi-putaran
- Memungkinkan fungsi hadiah melebihi batas waktu 15 menit
- Menyediakan algoritma canggih dan opsi penyetelan
- Dirancang untuk kasus penggunaan perusahaan yang kompleks, yang secara khusus disetel untuk membangun model perbatasan

Praktik terbaik:

Mulai kecil dan skala:

- Mulailah dengan kumpulan data minimal (100-200 contoh) dan beberapa zaman pelatihan
- Validasi pendekatan Anda sebelum meningkatkan
- Secara bertahap meningkatkan ukuran dataset dan langkah-langkah pelatihan berdasarkan hasil

Baseline dengan SFT terlebih dahulu:

- Jika skor hadiah secara konsisten rendah (misalnya, selalu 0), lakukan SFT sebelum RFT
- RFT membutuhkan kinerja dasar yang wajar untuk meningkatkan secara efektif

Desain fungsi hadiah yang efisien:

- Jalankan dalam hitungan detik, bukan menit
- Minimalkan panggilan API eksternal
- Gunakan algoritma dan struktur data yang efisien
- Menerapkan penanganan kesalahan yang tepat
- Uji secara menyeluruh sebelum pelatihan
- Memanfaatkan kemampuan penskalaan paralel Lambda

Pantau pelatihan secara aktif:

- Lacak skor hadiah rata-rata dari waktu ke waktu
- Tonton distribusi hadiah di seluruh sampel
- Bandingkan hadiah pelatihan vs. validasi
- Cari pola yang menyangkut (dataran tinggi, overfitting, ketidakstabilan)

Iterasi berdasarkan hasil:

- Jika reward tidak membaik setelah beberapa iterasi, sesuaikan desain fungsi reward
- Tingkatkan keragaman kumpulan data untuk memberikan sinyal pembelajaran yang lebih jelas
- Pertimbangkan untuk beralih ke SFT jika hadiah tetap mendekati nol

- Bereksperimenlah dengan hiperparameter yang berbeda (tingkat pembelajaran, ukuran batch)

Optimalkan kualitas data:

- Pastikan contoh yang beragam dan representatif
- Sertakan kasing tepi dan sampel yang sulit
- Verifikasi fungsi hadiah dengan benar menilai semua jenis contoh
- Hapus atau perbaiki sampel yang membingungkan fungsi hadiah

Pemecahan masalah

Kesalahan fungsi hadiah:

Gejala: Tingkat kesalahan tinggi dalam panggilan fungsi hadiah selama pelatihan

Isu	Gejala	Resolusi
Batas waktu Lambda	Batas waktu yang sering setelah 15 menit	Optimalkan kinerja fungsi; pertimbangkan Nova Forge untuk evaluasi kompleks
Konkurensi tidak cukup	Kesalahan pelambatan Lambda	Tingkatkan <code>lambda_concurrency_limit</code> atau minta kenaikan kuota
Format pengembalian tidak valid	Pelatihan gagal dengan kesalahan format	Verifikasi struktur pengembalian cocok dengan format antarmuka yang diperlukan
Pengecualian yang tidak tertangani	Kesalahan intermiten	Tambahkan penanganan kesalahan dan pencatatan yang komprehensif
Kegagalan API eksternal	Penilaian yang tidak konsisten	Menerapkan logika coba lagi dan strategi mundur

Kinerja pelatihan yang buruk:

Gejala: Imbalan tidak membaik atau mendatar pada nilai rendah

Resolusi:

- Verifikasi kebenaran fungsi hadiah: Uji dengan contoh yang diketahui good/bad
- Periksa kinerja dasar: Evaluasi model dasar; jika akurasi mendekati nol, lakukan SFT terlebih dahulu
- Tingkatkan keragaman data: Tambahkan contoh yang lebih bervariasi yang mencakup skenario berbeda
- Sesuaikan hiperparameter: Coba tingkat pembelajaran atau ukuran batch yang berbeda
- Tinjau kualitas sinyal hadiah: Pastikan hadiah membedakan antara respons yang baik dan buruk

Overfitting:

Gejala: Hadiah pelatihan meningkat sementara imbalan validasi menurun

Resolusi:

- Kurangi langkah pelatihan: Hentikan pelatihan lebih awal
- Tingkatkan ukuran kumpulan data: Tambahkan lebih banyak contoh pelatihan
- Tambahkan regularisasi: Sesuaikan atau `weight_decay` `entropy_coeff`
- Meningkatkan keragaman data: Pastikan set pelatihan mewakili distribusi penuh

Mengevaluasi model terlatih Anda

Resep evaluasi adalah file konfigurasi YAMM yang menentukan bagaimana pekerjaan evaluasi model Amazon Nova Anda dijalankan. Dengan resep ini, Anda dapat menilai kinerja model dasar atau terlatih terhadap tolok ukur umum atau kumpulan data khusus Anda sendiri. Metrik dapat disimpan di Amazon TensorBoard S3 atau. Evaluasi menyediakan metrik kuantitatif yang membantu Anda menilai kinerja model di berbagai tugas untuk menentukan apakah penyesuaian lebih lanjut diperlukan.

Evaluasi model adalah proses offline, di mana model diuji terhadap tolok ukur tetap dengan jawaban yang telah ditentukan. Mereka tidak dinilai secara real-time atau terhadap interaksi pengguna langsung. Untuk evaluasi real-time, Anda dapat mengevaluasi model setelah diterapkan ke Amazon Bedrock dengan memanggil runtime Amazon Bedrock. APIs

Topik

- [Tugas benchmark yang tersedia](#)
- [Memahami parameter resep](#)
- [Contoh resep evaluasi](#)
- [Memulai pekerjaan evaluasi](#)
- [Mengakses dan menganalisis hasil evaluasi](#)
- [Evaluasi RFT](#)

Tugas benchmark yang tersedia

Paket kode sampel tersedia yang menunjukkan cara menghitung metrik tolok ukur menggunakan fitur evaluasi model SageMaker AI untuk Amazon Nova. Untuk mengakses paket kode, lihat [Sampel-Nova-lighteval-custom-task](#).

Berikut adalah daftar tolok ukur standar industri yang didukung dan tersedia. Anda dapat menentukan tolok ukur berikut dalam `eval_task` parameter:

Tolok Ukur	Modalitas	Deskripsi	Metrik-metrik	Strategi	Subtugas Tersedia
mmlu	Teks	Pemahaman Bahasa Multi-tugas - Menguji pengetahuan di 57 mata pelajaran.	ketepatan	zs_cot	Ya
mmlu_pro	Teks	MMLU - Subset Profesional - Berfokus pada domain profesional seperti hukum,	ketepatan	zs_cot	Tidak

Tolok Ukur	Modalitas	Deskripsi	Metrik-metrik	Strategi	Subtugas Tersedia
		kedokteran, akuntansi, dan teknik.			
bbh	Teks	Tugas Penalaran Lanjutan - Kumpulan masalah menantang yang menguji keterampilan kognitif dan pemecahan masalah tingkat tinggi.	ketepatan	zs_cot	Ya
gpqa	Teks	Penjawab Pertanyaan Fisika Umum — Menilai pemahaman konsep fisika dan kemampuan pemecahan masalah terkait.	ketepatan	zs_cot	Tidak

Tolok Ukur	Modalitas	Deskripsi	Metrik-metrik	Strategi	Subtugas Tersedia
matematika	Teks	Pemecahan Masalah Matematika — Mengukur penalaran matematis di seluruh topik termasuk aljabar, kalkulus, dan masalah kata.	exact_match	zs_cot	Ya
strong_tolak	Teks	Quality-Control Task — Menguji kemampuan model untuk mendeteksi dan menolak konten yang tidak pantas, berbahaya, atau salah.	defleksi	zs	Ya

Tolok Ukur	Modalitas	Deskripsi	Metrik-metrik	Strategi	Subtugas Tersedia
IFEval	Teks	Instruksi-Mengikuti Evaluasi - Mengukur seberapa akurat model mengikuti instruksi yang diberikan dan menyelesaikan tugas untuk spesifikasi.	ketepatan	zs	Tidak
gen_qa	Teks	Evaluasi Dataset Kustom - Memungkinkan Anda membawa dataset Anda sendiri untuk benchmarking, membandingkan output model untuk referensi jawaban dengan metrik seperti ROUGE dan BLEU.	all	gen_qa	Tidak

Tolok Ukur	Modalitas	Deskripsi	Metrik-metrik	Strategi	Subtugas Tersedia
Ilm_hakim	Teks	LLM-as-a-Judge Perbandingan Preferensi — Menggunakan model Amazon Nova Judge untuk menentukan preferensi antara respons berpasangan (B dibandingkan dengan A) untuk permintaan Anda, menghitung probabilitas B lebih disukai daripada A.	all	hakim	Tidak

Tolok Ukur	Modalitas	Deskripsi	Metrik-metrik	Strategi	Subtugas Tersedia
kemanusiaan	Teks	HumanEval - Dataset benchmark yang dirancang untuk mengevaluasi kemampuan pembuatan kode model bahasa besar	lulus @1	zs	Tidak
mm_llm_hakim	Multi-modal (gambar)	Tolok ukur baru ini berperilaku sama dengan berbasis teks llm_judge di atas. Satu-satunya perbedaan adalah mendukung inferensi gambar.	all	hakim	Tidak

Tolok Ukur	Modalitas	Deskripsi	Metrik-metrik	Strategi	Subtugas Tersedia
rubric_llm_judge	Teks	Rubric Judge adalah model LLM-as-a-judge evaluasi yang disempurnakan yang dibangun di Amazon Nova 2.0 Lite. Berbeda dengan model hakim asli yang hanya memberikan putusan preferensi, Rubric Judge secara dinamis menghasilkan kriteria evaluasi khusus yang disesuaikan dengan setiap prompt dan memberikan skor granular di berbagai dimensi.	all	hakim	Tidak

Tolok Ukur	Modalitas	Deskripsi	Metrik-metrik	Strategi	Subtugas Tersedia
aime_2024	Teks	AIME 2024 - Ujian Matematik a Undangan Amerika menguji penalaran matematik a tingkat lanjut dan pemecahan masalah	exact_match	zs_cot	Tidak
calendar_scheduling	Teks	Rencana Alami - Kalender Penjadwalan tugas menguji kemampuan perencana an untuk menjadwal kan rapat di beberapa hari dan orang	exact_match	fs	Tidak

mm1uSubtugas berikut tersedia:

```
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"
]
```

bbhSubtugas berikut tersedia:

```
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"
]
```

mathSubtugas berikut tersedia:

```
MATH_SUBTASKS = [  
    "algebra",  
    "counting_and_probability",  
    "geometry",  
    "intermediate_algebra",  
    "number_theory",  
    "prealgebra",  
    "precalculus",  
]
```

Memahami parameter resep

Jalankan konfigurasi

Berikut ini adalah konfigurasi run umum dan penjelasan tentang parameter yang terlibat.

```
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:** (Wajib) Nama deskriptif untuk pekerjaan evaluasi Anda. Ini membantu mengidentifikasi pekerjaan Anda di AWS konsol.
- **model_type:** (Wajib) Menentukan varian model Amazon Nova yang akan digunakan. Jangan memodifikasi bidang ini secara manual. Opsinya meliputi:
 - `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:** (Wajib) Jalur ke model dasar atau jalur S3 untuk pos pemeriksaan pasca-terlatih. Opsinya meliputi:
 - `nova-micro/prod`

- nova-lite/prod
- nova-pro/prod
- nova-lite-2/prod
- (Jalur S3 untuk pos pemeriksaan pasca-terlatih) s3://<escrow bucket>/<job id>/outputs/checkpoints
- replicas: (Wajib) Jumlah instance komputasi yang akan digunakan untuk pelatihan terdistribusi. Anda harus menetapkan nilai ini ke 1 karena multi-node tidak didukung.
- data_s3_path: (Wajib) Jalur S3 ke dataset input. Biarkan parameter ini kosong kecuali Anda menggunakan set data atau LLM bawa sendiri sebagai resep juri.
- output_s3_path: (Wajib) Jalur S3 untuk menyimpan artefak evaluasi keluaran. Perhatikan bahwa bucket output S3 harus dibuat oleh akun yang sama yang membuat pekerjaan.
- mlflow_tracking_uri: (Opsional) server MLflow pelacakan ARN untuk melacak MLFlow jalanan/eksperimen. Pastikan Anda memiliki izin untuk mengakses server pelacakan dari peran eksekusi SageMaker AI

Konfigurasi evaluasi

Berikut ini adalah konfigurasi evaluasi model dan penjelasan tentang parameter yang terlibat.

```
evaluation:
  task: mmlu
  strategy: zs_cot
  subtask: mathematics
  metric: accuracy
```

- task: (Wajib) Menentukan benchmark evaluasi atau tugas untuk digunakan.

Daftar tugas yang didukung:

- mmlu
- mmlu_pro
- bbh
- gpqa
- matematika
- strong_tolak
- gen_qa

- ifeval
- llm_hakim
- kemanusiaan
- mm_llm_hakim
- rubric_llm_judge
- aime_2024
- calendar_scheduling
- kemanusiaan
- strategy: (Wajib) Mendefinisikan pendekatan evaluasi:
 - zs_cot: Zero-shot Chain-of-Thought - Pendekatan untuk mendorong model bahasa besar yang mendorong penalaran tanpa memerlukan contoh eksplisit. step-by-step
 - zs: Zero-shot - Pendekatan untuk memecahkan masalah tanpa contoh pelatihan sebelumnya.
 - gen_qa: Strategi khusus untuk bawa resep dataset Anda sendiri.
 - hakim: Strategi khusus untuk Amazon Nova LLM sebagai Hakim dan mm_llm_judge.
- subtask: (Opsional dan Dapat Dilepas) Menentukan subtugas tertentu untuk tugas evaluasi tertentu. Hapus ini dari resep Anda jika tugas Anda tidak memiliki subtugas.
- metric: (Wajib) Metrik evaluasi yang akan digunakan.
 - akurasi: Persentase jawaban yang benar
 - exact_match: (Untuk math benchmark), mengembalikan tingkat di mana string yang diprediksi input sama persis dengan referensi mereka.
 - defleksi: (Untuk strong reject benchmark), mengembalikan defleksi relatif ke model dasar dan perbedaan metrik signifikansi.
 - pass @1: (Untuk humaneval benchmark) adalah metrik yang digunakan untuk mengukur persentase kasus di mana prediksi kepercayaan tertinggi model cocok dengan jawaban yang benar.
 - all: Mengembalikan metrik berikut:
 - Untuk gen_qa dan bawa benchmark dataset Anda sendiri, kembalikan metrik berikut:
 - rouge1: Mengukur tumpang tindih unigram (kata tunggal) antara teks yang dihasilkan dan referensi.
 - rouge2: Mengukur tumpang tindih bigram (dua kata berturut-turut) antara teks yang dihasilkan dan referensi.

- `rougeL`: Mengukur urutan umum terpanjang antara teks, memungkinkan celah dalam pencocokan.
- `exact_match`: Skor biner (0 atau 1) menunjukkan apakah teks yang dihasilkan cocok dengan teks referensi persis, karakter demi karakter.
- `quasi_exact_match`: Mirip dengan kecocokan persis tetapi lebih lunak, biasanya mengabaikan kasus, tanda baca, dan perbedaan ruang putih.
- `f1_score`: Rata-rata harmonik presisi dan ingatan, mengukur tumpang tindih kata antara jawaban yang diprediksi dan referensi.
- `f1_score_quasi`: Mirip dengan `f1_score` tetapi dengan pencocokan yang lebih lunak, menggunakan perbandingan teks yang dinormalisasi yang mengabaikan perbedaan kecil.
- `bleu`: Mengukur presisi kecocokan n-gram antara teks yang dihasilkan dan referensi, yang biasa digunakan dalam evaluasi terjemahan.
- Untuk `llm_judge` dan `mm_llm_judge`, bawa benchmark dataset Anda sendiri, kembalikan metrik berikut:
 - `a_scores`: Jumlah kemenangan untuk `response_A` lintasan evaluasi maju dan mundur.
 - `a_scores_stderr`: Kesalahan standar `response_A scores` lintas penilaian berpasangan.
 - `b_scores`: Jumlah kemenangan untuk `response_B` lintasan evaluasi maju dan mundur.
 - `b_scores_stderr`: Kesalahan standar `response_B scores` lintas penilaian berpasangan.
 - `ties`: Jumlah penilaian di mana `response_A` dan `response_B` dievaluasi sebagai sama.
 - `ties_stderr`: Kesalahan standar ikatan di seluruh penilaian berpasangan.
 - `inference_error`: Hitungan penilaian yang tidak dapat dievaluasi dengan benar.
 - `inference_error_stderr`: Kesalahan standar kesalahan inferensi di seluruh penilaian.
 - `score`: Skor agregat berdasarkan kemenangan dari umpan maju dan mundur untuk `response_B`.
 - `score_stderr`: Kesalahan standar skor agregat di seluruh penilaian berpasangan.
 - `winrate`: probabilitas bahwa `response_B` akan lebih disukai daripada `response_A` dihitung menggunakan probabilitas Bradley-Terry.
 - `lower_rate`: Batas bawah (persentil 2.5) dari perkiraan tingkat kemenangan dari pengambilan sampel bootstrap.

Konfigurasi inferensi

Berikut ini adalah konfigurasi inferensi dan penjelasan tentang parameter yang terlibat. Semua parameter bersifat opsional.

```
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**: Jumlah maksimum token yang akan dihasilkan. Ini harus berupa bilangan bulat.
- **top_k**: Jumlah token probabilitas tertinggi untuk dipertimbangkan. Ini harus berupa bilangan bulat.
- **top_p**: Ambang probabilitas kumulatif untuk pengambilan sampel token. Ini harus berupa float antara 0,0 dan 1,0, inklusif.
- **temperature**: Keacakan dalam pemilihan token. Nilai yang lebih besar memperkenalkan lebih banyak keacakan. Gunakan 0 untuk membuat hasil deterministik. Nilai ini harus berupa float dengan nilai minimum 0.
- **top_logprobs**: Jumlah logprob teratas yang akan dikembalikan dalam respons inferensi. Nilai ini harus berupa bilangan bulat dari 0 hingga 20. Logprobs berisi token keluaran yang dipertimbangkan dan probabilitas log dari setiap token keluaran yang dikembalikan dalam konten pesan.
- **reasoning_effort**: mengontrol perilaku penalaran untuk model yang mampu beralasan. Tetapkan **reasoning_effort** hanya ketika **model_type** menentukan model berkemampuan penalaran (saat ini). **amazon.nova-2-lite-v1:0:256k** Opsi yang tersedia adalah **null** (nilai default jika tidak disetel; menonaktifkan penalaran), **low**, atau **high**

Perhatikan bahwa untuk **humaneval**, kami merekomendasikan konfigurasi inferensi berikut:

```
inference:
  top_k: 1
  max_new_tokens: 1600
  temperature: 0.0
```

MLFlow konfigurasi

Berikut ini adalah MLFlow konfigurasi dan penjelasan tentang parameter yang terlibat. Semua parameter bersifat opsional.

```
run:
  mlflow_tracking_uri: ""
  mlflow_experiment_name: ""
  mlflow_run_name: ""
```

- `mlflow_tracking_uri`: Opsional) Lokasi server MLflow pelacak (hanya diperlukan di SMHP)
- `mlflow_experiment_name`: (Opsional) Nama percobaan untuk mengelompokkan ML terkait berjalan bersama
- `mlflow_run_name`: (Opsional) Nama khusus untuk pelatihan tertentu yang dijalankan dalam eksperimen

Contoh resep evaluasi

Amazon Nova menyediakan empat jenis resep evaluasi, yang tersedia di GitHub repositori SageMaker HyperPod resep.

Resep tolok ukur teks umum

Resep-resep ini memungkinkan Anda untuk mengevaluasi kemampuan dasar model Amazon Nova di seluruh rangkaian tolok ukur khusus teks yang komprehensif. Mereka disediakan dalam `formatxxx_general_text_benchmark_eval.yaml`.

Bawa resep benchmark dataset Anda sendiri

Resep ini memungkinkan Anda untuk membawa dataset Anda sendiri untuk benchmarking dan membandingkan output model untuk referensi jawaban menggunakan berbagai jenis metrik. Mereka disediakan dalam `formatxxx_bring_your_own_dataset_eval.yaml`.

Berikut ini adalah persyaratan dataset Anda sendiri:

- Persyaratan format file
 - Anda harus menyertakan satu `gen_qa.jsonl` file yang berisi contoh evaluasi.
 - Dataset Anda harus diunggah ke lokasi S3 di mana pekerjaan SageMaker pelatihan dapat mengaksesnya.

- File harus mengikuti format skema yang diperlukan untuk kumpulan data Tanya Jawab umum.
- Persyaratan format skema - Setiap baris dalam file JSONL harus berupa objek JSON dengan bidang berikut:
 - **query:** (Wajib) String yang berisi pertanyaan atau instruksi yang membutuhkan jawaban
 - **response:** (Wajib) String yang berisi output model yang diharapkan
 - **system:** (Opsional) String yang berisi prompt sistem yang menetapkan perilaku, peran, atau kepribadian model AI sebelum memproses kueri
 - **metadata:** (Opsional) String yang berisi metadata yang terkait dengan entri untuk tujuan penandaan.

Berikut ini adalah entri contoh kumpulan data Anda sendiri

```
{
  "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"
}
```

Untuk menggunakan kumpulan data kustom Anda, ubah resep evaluasi Anda dengan bidang wajib berikut, jangan ubah konten apa pun:

```
evaluation:
  task: gen_qa
  strategy: gen_qa
  metric: all
```

Batasan berikut berlaku:

- Hanya satu file JSONL yang diizinkan per evaluasi.
- File harus benar-benar mengikuti skema yang ditentukan.
- Batas panjang konteks: Untuk setiap sampel dalam kumpulan data, panjang konteks (termasuk permintaan kueri sistem +) harus kurang dari 3,5k.

Nova LLM sebagai resep tolok ukur Hakim

Amazon Nova LLM sebagai Hakim adalah fitur evaluasi model yang memungkinkan pelanggan membandingkan kualitas respons dari satu model ke respons model dasar pada kumpulan data khusus. [Dibutuhkan kumpulan data dengan petunjuk, respons dasar, dan respons penantang, dan menggunakan model Amazon Nova Judge untuk memberikan metrik winrate berdasarkan probabilitas Bradley-Terry dengan perbandingan berpasangan.](#)

Resep disediakan dalam format `xxx_llm_judge_eval.yaml`.

Berikut ini adalah LLM sebagai persyaratan Hakim:

- Persyaratan format file
 - Sertakan satu `llm_judge.jsonl` file yang berisi contoh evaluasi. Nama file harus `llm_judge.jsonl`.
 - Dataset Anda harus diunggah ke lokasi S3 yang dapat diakses [SageMaker AI SageMaker HyperPod RIG](#).
 - File harus mengikuti format skema yang diperlukan untuk `llm_judge.jsonl` kumpulan data.
 - Dataset input harus memastikan semua catatan berada di bawah panjang konteks 12k.
- Persyaratan format skema - Setiap baris dalam file JSONL harus berupa objek JSON dengan bidang berikut:
 - `prompt`: (Wajib) String yang berisi prompt untuk respons yang dihasilkan.
 - `response_A`: String yang berisi respons dasar.
 - `response_B`: String yang berisi respons alternatif dibandingkan dengan respons dasar.

Berikut adalah LLM sebagai entri contoh juri

```
{
  "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."
}
```

Untuk menggunakan kumpulan data kustom Anda, ubah resep evaluasi Anda dengan bidang wajib berikut, jangan ubah konten apa pun:

```
evaluation:
  task: llm_judge
  strategy: judge
  metric: all
```

Batasan berikut berlaku:

- Hanya satu file JSONL yang diizinkan per evaluasi.
- File harus benar-benar mengikuti skema yang ditentukan.
- Model Amazon Nova Judge sama di semua spesifikasi keluarga model (yaitu, Lite, Micro, dan Pro).
- Model juri khusus tidak didukung saat ini.

- Batas panjang konteks: Untuk setiap sampel dalam kumpulan data, panjang konteks (termasuk permintaan kueri sistem +) harus kurang dari 7k.

Nova LLM sebagai Hakim untuk resep benchmark multi-modal (gambar)

Nova LLM Judge for multi-modal (image), kependekan dari Amazon Nova MM_LLM Judge, adalah fitur evaluasi model yang memungkinkan Anda membandingkan kualitas respons dari satu model dengan respons model dasar menggunakan kumpulan data khusus. [Ini menerima kumpulan data yang berisi petunjuk, respons dasar, dan respons penantang, dan gambar dalam bentuk string yang dikodekan Base64, kemudian menggunakan model Amazon Nova Judge untuk memberikan metrik tingkat kemenangan berdasarkan probabilitas Bradley-Terry melalui perbandingan berpasangan.](#)

Format resep: `xxx_mm_llm_judge_eval.yaml`.

Persyaratan set data Nova LLM

Format berkas:

- `mm_llm_judge.jsonl` File tunggal yang berisi contoh evaluasi. Nama file harus `persis_llm_judge.jsonl`.
- Anda harus mengunggah kumpulan data Anda ke lokasi S3 tempat SageMaker Training Jobs dapat mengaksesnya.
- File harus mengikuti format skema yang diperlukan untuk `mm_llm_judge` kumpulan data.
- Dataset input harus memastikan semua catatan berada di bawah panjang konteks 12 k, tidak termasuk atribut gambar.

Format skema - Setiap baris dalam `.jsonl` file harus berupa objek JSON dengan bidang berikut.

- Bidang yang diperlukan.

`prompt`: String yang berisi prompt untuk respons yang dihasilkan.

`images`: Array yang berisi daftar objek dengan atribut data (nilainya adalah string gambar yang dikodekan Base64).

`response_A`: String yang berisi respons dasar.

`response_B`: String yang berisi respons alternatif dibandingkan dengan respons dasar.

Entri contoh

Untuk keterbacaan, contoh berikut mencakup baris dan lekukan baru, tetapi dalam kumpulan data yang sebenarnya, setiap catatan harus berada pada satu baris.

```
{
  "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",
}
```

Untuk menggunakan kumpulan data kustom Anda, ubah resep evaluasi Anda dengan bidang wajib berikut, jangan ubah konten apa pun:

```
evaluation:
  task: mm_llm_judge
  strategy: judge
  metric: all
```

Batasan

- Hanya satu `.jsonl` file yang diizinkan per evaluasi.
- File harus benar-benar mengikuti skema yang ditentukan.

- Model Nova MM Judge hanya mendukung referensi gambar.
- Model Nova MM Judge sama di seluruh spesifikasi Amazon Nova Lite.
- Model juri khusus saat ini tidak didukung.
- URI gambar Amazon S3 tidak didukung.
- Dataset input harus memastikan semua catatan berada di bawah panjang konteks 12 k, tidak termasuk atribut gambar.

Hakim Berbasis Rubrik

Rubric Judge adalah model LLM-as-a-judge evaluasi yang disempurnakan yang dibangun di Amazon Nova 2.0 Lite. Berbeda dengan [model hakim asli](#) yang hanya memberikan putusan preferensi (A>B, B>A, atau dasi), Rubric Judge secara dinamis menghasilkan kriteria evaluasi khusus yang disesuaikan dengan setiap prompt dan memberikan skor granular di berbagai dimensi.

Kemampuan kunci:

- Pembuatan kriteria dinamis: Secara otomatis membuat dimensi evaluasi yang relevan berdasarkan prompt input
- Skor tertimbang: Menetapkan bobot kepentingan untuk setiap kriteria untuk mencerminkan signifikansi relatifnya
- Penilaian granular: Memberikan skor terperinci berdasarkan biner (benar/salah) atau skala (1-5) untuk setiap kriteria
- Metrik kualitas: Menghitung skor kualitas berkelanjutan (skala 0-1) yang mengukur besarnya perbedaan antara respons

Contoh kriteria yang dihasilkan oleh model:

```
price_validation:
  description: "The response includes validation to ensure price is a positive value."
  type: "scale"
  weight: 0.3
```

Model mengevaluasi kedua tanggapan terhadap semua kriteria yang dihasilkan, kemudian menggunakan skor tingkat kriteria ini untuk menginformasikan keputusan preferensi akhirnya.

Topik

- [Konfigurasi resep](#)
- [Format dataset masukan](#)
- [Keluaran evaluasi](#)
- [Dukungan model penalaran](#)

Konfigurasi resep

Resep Rubrik Hakim

Aktifkan Rubric Judge dengan menyetel task: `rubric_llm_judge` resep Anda:

```
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)
```

LLM asli sebagai resep Hakim (untuk perbandingan)

Model juri asli menggunakan task: `llm_judge`:

```
run:
  name: eval-job-name                                # [MODIFIABLE] Unique
  identifier for your evaluation job
  model_type: amazon.nova-micro-v1:0:128k             # [FIXED] Model type
  model_name_or_path: "nova-micro/prod"               # [FIXED] Path to model
  checkpoint or identifier
  replicas: 1                                           # [MODIFIABLE] Number of
  replicas for SageMaker Training job
  data_s3_path: ""                                    # [FIXED] Leave empty for
  SageMaker Training job
  output_s3_path: ""                                  # [FIXED] Leave empty for
  SageMaker Training job

evaluation:
  task: llm_judge                                     # [FIXED] Original judge task
  strategy: judge                                     # [FIXED] Evaluation strategy
  metric: all                                          # [FIXED] Metric calculation
  method

inference:
  max_new_tokens: 12000                               # [MODIFIABLE] Maximum tokens
  to generate
  top_k: -1                                            # [MODIFIABLE] Top-k sampling
  parameter
  top_p: 1.0                                           # [MODIFIABLE] Nucleus sampling
  parameter
  temperature: 0                                       # [MODIFIABLE] Sampling
  temperature (0 = deterministic)
```

Format dataset masukan

Format dataset input identik dengan [model juri asli](#):

Bidang yang diperlukan:

- `prompt`: String yang berisi prompt input dan instruksi
- `response_A`: String yang berisi keluaran model dasar
- `response_B`: String yang berisi output model yang disesuaikan

Contoh kumpulan data (format JSONL):

```
{
  "prompt": "What is the most effective way to combat climate change?",
  "response_A": "The most effective way to combat climate change is through a combination of transitioning to renewable energy sources and implementing strict carbon pricing policies. This creates economic incentives for businesses to reduce emissions while promoting clean energy adoption.",
  "response_B": "We should focus on renewable energy. Solar and wind power are good. People should drive electric cars. Companies need to pollute less."
}
{
  "prompt": "Explain how a computer's CPU works",
  "response_A": "CPU is like brain of computer. It does math and makes computer work fast. Has lots of tiny parts inside.",
  "response_B": "A CPU (Central Processing Unit) functions through a fetch-execute cycle, where instructions are retrieved from memory, decoded, and executed through its arithmetic logic unit (ALU). It coordinates with cache memory and registers to process data efficiently using binary operations."
}
{
  "prompt": "How does photosynthesis work?",
  "response_A": "Plants do photosynthesis to make food. They use sunlight and water. It happens in leaves.",
  "response_B": "Photosynthesis is a complex biochemical process where plants convert light energy into chemical energy. They utilize chlorophyll to absorb sunlight, combining CO2 and water to produce glucose and oxygen through a series of chemical reactions in chloroplasts."
}
```

Persyaratan format:

- Setiap entri harus berupa objek JSON satu baris
- Pisahkan entri dengan baris baru
- Ikuti penamaan bidang yang tepat seperti yang ditunjukkan pada contoh

Keluaran evaluasi

Struktur keluaran

Rubric Judge menghasilkan metrik evaluasi yang ditingkatkan dibandingkan dengan model juri asli:

```
{
  "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"
  }
}

```

Metrik baru di Rubric Judge

Enam metrik berikut unik untuk Rubric Judge dan memberikan penilaian kualitas terperinci:

Metrik	Deskripsi
Weighted_Score_A	Skor kualitas rata-rata yang dinormalisasi untuk Response_a di semua kriteria evaluasi yang dihasilkan model. Skor ditimbang berdasarkan

Metrik	Deskripsi
	kriteria kepentingan dan dinormalisasi ke skala 0-1 (lebih tinggi = kualitas yang lebih baik)
Weighted_Score_A_Stderr	Kesalahan standar rata-rata untuk Weighted_score_A, menunjukkan ketidakpastian statistik
Weighted_Score_B	Skor kualitas rata-rata yang dinormalisasi untuk Response_b di semua kriteria evaluasi yang dihasilkan model. Skor ditimbang berdasarkan kriteria kepentingan dan dinormalisasi ke skala 0-1 (lebih tinggi = kualitas yang lebih baik)
Weighted_Score_B_Stderr	Kesalahan standar rata-rata untuk Weighted_score_B, menunjukkan ketidakpastian statistik
score_margin	Perbedaan antara skor tertimbang (dihitung sebagai Weighted_score_A - Weighted_score_b). Rentang: -1.0 hingga 1.0. Positif = Response_A lebih baik; negatif = response_B lebih baik; mendekati nol = kualitas serupa
score_margin_stderr	Kesalahan standar rata-rata untuk score_margin, menunjukkan ketidakpastian dalam pengukuran perbedaan kualitas

Memahami metrik skor tertimbang

Tujuan: Skor tertimbang memberikan pengukuran kualitas berkelanjutan yang melengkapi putusan preferensi biner, memungkinkan wawasan yang lebih dalam tentang kinerja model.

Perbedaan utama dari hakim asli:

- Hakim asli: Hanya menampilkan preferensi diskrit ($A > B$, $B > A$, $A = B$)
- Hakim Rubrik: Menghasilkan preferensi DAN skor kualitas berkelanjutan (skala 0-1) berdasarkan kriteria khusus

Menafsirkan score_margin:

- `score_margin = -0.128`: Response_B mencetak 12,8 poin persentase lebih tinggi dari Response_a
- `|score_margin| < 0.1`: Perbedaan kualitas yang sempit (keputusan dekat)
- `|score_margin| > 0.2`: Perbedaan kualitas yang jelas (keputusan percaya diri)

Kasus penggunaan:

- Peningkatan model: Identifikasi area spesifik di mana model Anda berkinerja buruk
- Kuantifikasi kualitas: Ukur besarnya kesenjangan kinerja, bukan hanya rasio win/loss
- Penilaian kepercayaan: Bedakan antara keputusan dekat dan perbedaan kualitas yang jelas

Important

Putusan akhir masih didasarkan pada label preferensi eksplisit model hakim untuk mempertahankan penalaran holistik dan memastikan mitigasi bias posisi yang tepat melalui evaluasi. forward/backward Skor tertimbang berfungsi sebagai alat observabilitas, bukan sebagai pengganti putusan utama.

Metodologi perhitungan

Skor tertimbang dihitung melalui proses berikut:

- Ekstrak data kriteria: Parse output YAMM juri untuk mengekstrak skor kriteria dan bobot
- Menormalkan skor:
 - Kriteria tipe skala (1-5): Normalisasi ke 0-1 dengan menghitung $(score - 1) / 4$
 - Kriteria biner (benar/salah): Konversi ke 1.0/0.0
- Terapkan bobot: Kalikan setiap skor yang dinormalisasi dengan berat kriterianya
- Agregat: Jumlahkan semua skor tertimbang untuk setiap respons
- Hitung margin: Hitung `score_margin = weighted_score_A - weighted_score_B`

Contoh: Jika response_A memiliki jumlah tertimbang 0,65 dan response_B memiliki 0,78, `score_margin` maka akan menjadi -0,13, menunjukkan response_B adalah 13 poin persentase lebih tinggi dalam kualitas di semua kriteria tertimbang.

Dukungan model penalaran

Dukungan model penalaran memungkinkan evaluasi dengan model Amazon Nova berkemampuan penalaran yang melakukan penalaran internal eksplisit sebelum menghasilkan tanggapan akhir. Fitur ini menggunakan kontrol tingkat API melalui `reasoning_effort` parameter untuk mengaktifkan atau menonaktifkan fungsionalitas penalaran secara dinamis, berpotensi meningkatkan kualitas respons untuk tugas analitis yang kompleks.

Model yang didukung:

- `amazon.nova-2-lite-v 1:0:256 k`

Konfigurasi resep

Aktifkan penalaran dengan menambahkan `reasoning_effort` parameter ke inference bagian resep Anda:

```
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)

```

Menggunakan parameter `reasoning_effort`

`reasoning_effort` Parameter mengontrol perilaku penalaran untuk model berkemampuan penalaran.

Prasyarat:

- Kompatibilitas model: Setel `reasoning_effort` hanya ketika `model_type` menentukan model berkemampuan penalaran (saat ini) `amazon.nova-2-lite-v1:0:256k`
- Penanganan kesalahan: Menggunakan `reasoning_effort` dengan model yang tidak didukung akan gagal `ConfigValidationError: "Reasoning mode is enabled but model '{model_type}' does not support reasoning. Please use a reasoning-capable model or disable reasoning mode."`

Pilihan yang tersedia:

Opsi	Perilaku	Batas Token	Kasus Penggunaan
null (default)	Menonaktifkan mode penalaran	N/A	Evaluasi standar tanpa overhead penalaran
rendah	Memungkinkan penalaran dengan kendala	4.000 token untuk penalaran internal	Skenario yang membutuhkan penalaran ringkas; mengoptimalkan kecepatan dan biaya

Opsi	Perilaku	Batas Token	Kasus Penggunaan
tinggi	Memungkinkan penalaran tanpa kendala	Tidak ada batasan token pada penalaran internal	Masalah kompleks yang membutuhkan analisis dan step-by-step penalaran ekstensif

Kapan mengaktifkan penalaran

Gunakan mode penalaran (**low**, **medium**, atau **high**) untuk:

- Tugas pemecahan masalah yang kompleks (matematika, teka-teki logika, pengkodean)
- Pertanyaan analitis multi-langkah yang membutuhkan penalaran menengah
- Tugas di mana penjelasan atau step-by-step pemikiran terperinci meningkatkan akurasi
- Skenario di mana kualitas respons diprioritaskan daripada kecepatan

Gunakan mode non-penalaran (hilangkan parameter) untuk:

- Tanya Jawab sederhana atau pertanyaan faktual
- Tugas menulis kreatif
- Ketika waktu respons yang lebih cepat sangat penting
- Perbandingan kinerja di mana overhead penalaran harus dikecualikan
- Optimalisasi biaya saat penalaran tidak meningkatkan kinerja tugas

Pemecahan masalah

Kesalahan: “Mode penalaran diaktifkan tetapi model tidak mendukung penalaran”

Penyebab: `reasoning_effort` Parameter disetel ke nilai non-null, tetapi yang ditentukan `model_type` tidak mendukung penalaran.

Resolusi:

- Verifikasi jenis model Anda `amazon.nova-2-lite-v1:0:256k`

- Jika menggunakan model yang berbeda, beralihlah ke model berkemampuan penalaran atau hapus `reasoning_effort` parameter dari resep Anda

Memulai pekerjaan evaluasi

Berikut ini menyediakan jenis instans evaluasi yang disarankan dan konfigurasi tipe model:

```
# 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]
```

Anda juga harus dapat melihat status pekerjaan melalui konsol cluster Amazon EKS.

Mengakses dan menganalisis hasil evaluasi

Setelah pekerjaan evaluasi Anda selesai dengan sukses, Anda dapat mengakses dan menganalisis hasilnya menggunakan informasi di bagian ini. Berdasarkan `output_s3_path` (seperti `s3://output_path/`) yang didefinisikan dalam resep, struktur output adalah sebagai berikut:

```
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]
```

Hasil metrik disimpan di lokasi output S3 yang ditentukan. `s3://output_path/job_name/eval-result/result-timestamp.json`

Hasil tensorboard disimpan di jalur S3. `s3://output_path/job_name/eval-tensorboard-result/eval/event.out.tfevents.epoch+ip`

Semua output inferensi, kecuali untuk `llm_judge` dan `strong_reject`, disimpan di jalur S3: `s3://output_path/job_name/eval-result/details/model/taskname.parquet`

Untuk `gen_qa`, `inference_output.jsonl` file berisi bidang berikut untuk setiap objek JSON:

- prompt - Prompt akhir yang dikirimkan ke model
- inferensi - Output inferensi mentah dari model
- gold - Respon target dari dataset input
- metadata - String metadata dari dataset input jika disediakan

Untuk memvisualisasikan metrik evaluasi Anda di Tensorboard, selesaikan langkah-langkah berikut:

1. Arahkan ke SageMaker AI Tensorboard.
2. Pilih folder S3.
3. Tambahkan jalur folder S3 Anda, misal `s3://output_path/job-name/eval-tensorboard-result/eval`.
4. Tunggu sinkronisasi selesai.

Deret waktu, skalar, dan visualisasi teks tersedia.

Kami merekomendasikan praktik terbaik berikut:

- Jaga agar jalur keluaran Anda diatur berdasarkan model dan tipe benchmark.
- Pertahankan konvensi penamaan yang konsisten untuk memudahkan pelacakan.
- Simpan hasil yang diekstraksi di lokasi yang aman.
- Pantau status TensorBoard sinkronisasi untuk pemuatan data yang berhasil.

Anda dapat menemukan log kesalahan SageMaker HyperPod pekerjaan di grup CloudWatch log `aws/sagemaker/Clusters/cluster-id`.

Format Keluaran Probabilitas Log

Ketika `top_logprobs` dikonfigurasi dalam pengaturan inferensi Anda, output evaluasi mencakup probabilitas log tingkat token dalam file parquet. Setiap posisi token berisi kamus token kandidat teratas dengan probabilitas log mereka dalam struktur berikut:

```
{
  "Ġint": {"logprob_value": -17.8125, "decoded_value": " int"},
  "Ġthe": {"logprob_value": -2.345, "decoded_value": " the"}
}
```

Setiap entri token berisi:

- `logprob_value`: Nilai probabilitas log untuk token
- `decoded_value`: Representasi string decoded yang dapat dibaca manusia dari token

Token tokenizer mentah digunakan sebagai kunci kamus untuk memastikan keunikan, sekaligus `decoded_value` memberikan interpretasi yang dapat dibaca.

Evaluasi RFT

Note

Evaluasi melalui fungsi hadiah jarak jauh di AWS lingkungan Anda sendiri hanya tersedia jika Anda adalah pelanggan Amazon Nova Forge.

Important

Bidang `rl_env` konfigurasi digunakan secara eksklusif untuk evaluasi, bukan untuk pelatihan. Selama pelatihan, Anda mengonfigurasi fungsi reward menggunakan infrastruktur `reward_lambda_arn` (single-turn) atau BYOO dengan `rollout.delegate: true` (multi-turn).

Apa itu Evaluasi RFT?

Evaluasi RFT memungkinkan Anda menilai kinerja model Anda menggunakan fungsi hadiah khusus sebelum, selama, atau setelah pelatihan pembelajaran penguatan. Tidak seperti evaluasi standar yang menggunakan metrik yang telah ditentukan sebelumnya, Evaluasi RFT memungkinkan Anda menentukan kriteria keberhasilan Anda sendiri melalui fungsi Lambda yang menilai output model berdasarkan kebutuhan spesifik Anda.

Mengapa Evaluasi dengan RFT?

Evaluasi sangat penting untuk menentukan apakah proses fine-tuning RL memiliki:

- Penyelarasan model yang ditingkatkan dengan kasus penggunaan spesifik dan nilai-nilai kemanusiaan Anda
- Mempertahankan atau meningkatkan kemampuan model pada tugas-tugas utama

- Menghindari efek samping yang tidak diinginkan seperti berkurangnya faktualitas, peningkatan verbositas, atau penurunan kinerja pada tugas-tugas lain
- Memenuhi kriteria keberhasilan khusus Anda seperti yang ditentukan oleh fungsi hadiah Anda

Kapan Menggunakan Evaluasi RFT

Gunakan Evaluasi RFT dalam skenario ini:

- Sebelum Pelatihan RFT: Tetapkan metrik dasar pada kumpulan data evaluasi Anda
- Selama Pelatihan RFT: Pantau kemajuan pelatihan dengan pos pemeriksaan menengah
- Setelah Pelatihan RFT: Validasi bahwa model akhir memenuhi kebutuhan Anda
- Membandingkan Model: Mengevaluasi beberapa versi model menggunakan kriteria hadiah yang konsisten

Note

Gunakan Evaluasi RFT saat Anda membutuhkan metrik khusus domain khusus. Untuk evaluasi tujuan umum (akurasi, kebingungan, BLEU), gunakan metode evaluasi standar.

Topik

- [Persyaratan format data](#)
- [Mempersiapkan resep evaluasi Anda](#)
- [Fungsi hadiah preset](#)
- [Membuat fungsi hadiah Anda](#)
- [Izin IAM](#)
- [Melaksanakan pekerjaan evaluasi](#)
- [Memahami hasil evaluasi](#)

Persyaratan format data

Struktur data masukan

Data input evaluasi RFT harus mengikuti format Fine-Tuning Penguatan OpenAI. Setiap contoh adalah objek JSON yang berisi:

- **messages:** Array giliran percakapan dengan system dan peran user
- Metadata opsional lainnya, misalnya `reference_answer`

Contoh format data

Contoh berikut menunjukkan format yang diperlukan:

```
{
  "messages": [
    {
      "role": "user",
      "content": [
        {
          "type": "text",
          "text": "Solve for x. Return only JSON like {\"x\": <number>}. Equation: 2x + 5 = 13"
        }
      ]
    }
  ],
  "reference_answer": {
    "x": 4
  }
}
```

Keterbatasan saat ini

Batasan berikut berlaku untuk evaluasi RFT:

- Hanya teks: Tidak ada input multimodal (gambar, audio, video) yang didukung
- Percakapan satu putaran: Hanya mendukung pesan pengguna tunggal (tidak ada dialog multi-putaran)
- Format JSON: Data input harus dalam format JSONL (satu objek JSON per baris)
- Output model: Evaluasi dilakukan pada penyelesaian yang dihasilkan dari model yang ditentukan

Mempersiapkan resep evaluasi Anda

Contoh konfigurasi resep

Contoh berikut menunjukkan resep evaluasi RFT lengkap:

```

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>

```

Fungsi hadiah preset

Dua fungsi hadiah preset (`prime_codedanprime_math`) tersedia sebagai lapisan Lambda untuk memudahkan integrasi dengan fungsi Lambda RFT Anda.

Ikhtisar

Fungsi preset ini memberikan kemampuan out-of-the-box evaluasi untuk:

- `prime_code`: Pembuatan kode dan evaluasi kebenaran
- `prime_math`: Penalaran matematis dan evaluasi pemecahan masalah

Pengaturan cepat

Untuk menggunakan fungsi hadiah preset:

1. [Unduh layer Lambda dari rilis nova-custom-eval-sdk](#)
2. Publikasikan lapisan Lambda menggunakan CLI AWS :

```
aws lambda publish-layer-version \
  --layer-name preset-function-layer \
  --description "Preset reward function layer with dependencies" \
  --zip-file fileb://universal_reward_layer.zip \
  --compatible-runtimes python3.9 python3.10 python3.11 python3.12 \
  --compatible-architectures x86_64 arm64
```

3. Tambahkan layer ke fungsi Lambda Anda di AWS Console (Pilih `preset-function-layer` dari lapisan kustom dan juga tambahkan `AWSSDKPandas-Python 312` untuk dependensi `numpy`)
4. Impor dan gunakan dalam kode Lambda Anda:

```
from prime_code import compute_score # For code evaluation
from prime_math import compute_score # For math evaluation
```

fungsi `prime_code`

Tujuan: Mengevaluasi tugas pembuatan kode Python dengan mengeksekusi kode terhadap kasus uji dan mengukur kebenaran.

Contoh format dataset masukan dari evaluasi:

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

Fitur utama:

- Ekstraksi kode otomatis dari blok kode penurunan harga
- Deteksi fungsi dan pengujian berbasis panggilan
- Eksekusi kasus uji dengan perlindungan batas waktu
- Validasi sintaks dan pemeriksaan kompilasi
- Pelaporan kesalahan terperinci dengan traceback

fungsi prime_math

Tujuan: Mengevaluasi penalaran matematika dan kemampuan pemecahan masalah dengan dukungan matematika simbolis.

Format masukan:

```
{"messages":[{"role":"user","content":"What is the derivative of x^2 + 3x?."}], "reference_answer":"2*x + 3"}
```

Fitur utama:

- Evaluasi matematika simbolik menggunakan SymPy
- Beberapa format jawaban (LaTeX, teks biasa, simbolik)
- Pemeriksaan kesetaraan matematika
- Normalisasi dan penyederhanaan ekspresi

Praktik terbaik

Ikuti praktik terbaik ini saat menggunakan fungsi hadiah preset:

- Gunakan tipe data yang tepat dalam kasus uji (bilangan bulat vs string, boolean vs “True”)
- Berikan tanda tangan fungsi yang jelas dalam masalah kode
- Sertakan kasus tepi dalam input pengujian (nol, angka negatif, input kosong)
- Format ekspresi matematika secara konsisten dalam jawaban referensi
- Uji fungsi reward Anda dengan data sampel sebelum penerapan

Membuat fungsi hadiah Anda

Lambda ARN

Anda harus merujuk ke format berikut untuk Lambda ARN:

```
"arn:aws:lambda:*:*:function:*SageMaker*"
```

Jika Lambda tidak memiliki skema penamaan ini, pekerjaan akan gagal dengan kesalahan ini:

```
[ERROR] Unexpected error: lambda_arn must contain one of: ['SageMaker', 'sagemaker', 'Sagemaker'] when running on SMHP platform (Key: lambda_arn)
```

Struktur fungsi Lambda

Fungsi Lambda Anda menerima batch output model dan mengembalikan skor hadiah. Di bawah ini adalah contoh implementasi:

```
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

```

Format permintaan Lambda

Fungsi Lambda Anda menerima data dalam format ini:

```

[
  {
    "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

Struktur pesan mencakup content array bersarang, cocok dengan format data input. Pesan terakhir dengan peran nova_assistant berisi respons yang dihasilkan model.

Format respons Lambda

Fungsi Lambda Anda harus mengembalikan data dalam format ini:

```
[  
  {  
    "id": "sample-001",  
    "aggregate_reward_score": 0.75,  
    "metrics_list": [  
      {  
        "name": "accuracy",  
        "value": 0.85,  
        "type": "Metric"  
      },  
      {  
        "name": "fluency",  
        "value": 0.90,  
        "type": "Reward"  
      }  
    ]  
  }  
]
```

Bidang respons:

- **id:** Harus cocok dengan ID sampel input

- `aggregate_reward_score`: Skor keseluruhan (biasanya 0,0 hingga 1,0)
- `metrics_list`: Array metrik individu dengan:
 - `name`: Pengidentifikasi metrik (misalnya, “akurasi”, “kelancaran”)
 - `value`: Skor metrik (biasanya 0,0 hingga 1,0)
 - `type`: Baik “Metrik” (untuk pelaporan) atau “Hadiah” (digunakan dalam pelatihan)

Izin IAM

Izin yang diperlukan

Peran eksekusi SageMaker AI Anda harus memiliki izin untuk menjalankan fungsi Lambda Anda. Tambahkan kebijakan ini ke peran eksekusi SageMaker AI Anda:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "lambda:InvokeFunction"
      ],
      "Resource": "arn:aws:lambda:region:account-id:function:function-name"
    }
  ]
}
```

Peran pelaksanaan Lambda

Peran eksekusi fungsi Lambda Anda memerlukan izin eksekusi Lambda dasar:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "logs:CreateLogGroup",
        "logs:CreateLogStream",
        "logs:PutLogEvents"
      ],

```

```
    "Resource": "arn:aws:logs:*:*:*"
  }
]
}
```

Izin tambahan: Jika fungsi Lambda Anda mengakses layanan AWS lain (misalnya, Amazon S3 untuk data referensi, DynamoDB untuk pencatatan), tambahkan izin tersebut ke peran eksekusi Lambda.

Melaksanakan pekerjaan evaluasi

1. Siapkan data Anda

- Format data evaluasi Anda sesuai dengan persyaratan format data
- Unggah file JSONL Anda ke Amazon S3: `s3://your-bucket/eval-data/eval_data.jsonl`

2. Konfigurasi resep Anda

Perbarui resep sampel dengan konfigurasi Anda:

- Setel `model_name_or_path` ke lokasi model Anda
- Setel `lambda_arn` ke ARN fungsi reward Anda
- Setel `output_s3_path` ke lokasi keluaran yang Anda inginkan
- Sesuaikan `inference` parameter sesuai kebutuhan

Simpan resepnya sebagai `rft_eval_recipe.yaml`

3. Jalankan evaluasi

Jalankan pekerjaan evaluasi menggunakan notebook yang disediakan: [Notebook evaluasi model Nova](#)

4. Pantau kemajuan

Pantau pekerjaan evaluasi Anda melalui:

- SageMaker Konsol AI: Periksa status pekerjaan dan log
- CloudWatch Log: Lihat log eksekusi terperinci
- Lambda Logs: Masalah fungsi hadiah debug

Memahami hasil evaluasi

Format output

Pekerjaan evaluasi menghasilkan hasil ke lokasi Amazon S3 yang Anda tentukan dalam format JSONL. Setiap baris berisi hasil evaluasi untuk satu sampel:

```
{
  "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

Output Pekerjaan Evaluasi RFT identik dengan format Respons Lambda. Layanan evaluasi melewati respons fungsi Lambda Anda tanpa modifikasi, memastikan konsistensi antara perhitungan hadiah Anda dan hasil akhir.

Menafsirkan hasil

Skor Hadiah Agregat:

- Rentang: Biasanya 0,0 (terburuk) hingga 1,0 (terbaik), tetapi tergantung pada implementasi Anda
- Tujuan: Angka tunggal yang merangkum kinerja keseluruhan
- Penggunaan: Bandingkan model, lacak peningkatan selama pelatihan

Metrik Individu:

- Jenis Metrik: Metrik informasi untuk analisis
- Jenis Hadiah: Metrik yang digunakan selama pelatihan RFT
- Interpretasi: Nilai yang lebih tinggi umumnya menunjukkan kinerja yang lebih baik (kecuali jika Anda merancang metrik terbalik)

Tolok ukur kinerja

Apa yang dimaksud dengan kinerja “baik” tergantung pada kasus penggunaan Anda:

Rentang Skor	Interpretasi	Tindakan
0,8 - 1,0	Sangat baik	Model siap untuk penyebaran
0,6 - 0,8	Baik	Perbaikan kecil mungkin bermanfaat
0,4 - 0,6	Adil	Diperlukan peningkatan yang signifikan
0,0 - 0,4	Miskin	Tinjau data pelatihan dan fungsi hadiah

Important

Ini adalah pedoman umum. Tentukan ambang batas Anda sendiri berdasarkan persyaratan bisnis, kinerja model dasar, kendala khusus domain, dan analisis biaya-manfaat pelatihan lebih lanjut.

Memantau HyperPod pekerjaan dengan MLflow

Anda dapat menggunakan MLflow untuk melacak dan memantau pekerjaan pelatihan Anda SageMaker HyperPod. Ikuti langkah-langkah ini untuk mengatur MLflow dan menghubungkannya ke resep pelatihan Anda.

Buat MLflow Aplikasi

Contoh AWS CLI perintah

```
aws sagemaker-mlflow create-mlflow-app \  
  --name <app-name> \  
  --artifact-store-uri <s3-bucket-name> \  
  --role-arn <role-arn> \  
  --region <region-name>
```

Contoh Output

```
{  
  "Arn": "arn:aws:sagemaker:us-east-1:111122223333:mlflow-app/app-LGZE0Z2UY4NZ"  
}
```

Hasilkan URL yang telah ditandatangani sebelumnya

Contoh AWS CLI perintah

```
aws sagemaker-mlflow create-presigned-mlflow-app-url \  
  --arn <app-arn> \  
  --region <region-name> \  
  --output text
```

Contoh Output


```
https://app-LGZE0Z2UY4NZ.mlflow.sagemaker.us-east-1.app.aws/auth?  
authToken=eyJhbGciOiJIUzI1NiJ9.eyJhdXRoVG9rZW5JZCI6IkxETVBPUyIsImZhc0NyZWRLbnRpYWxzIjoiaWdWNGhD
```

Buka URL yang telah ditetapkan sebelumnya dan lihat aplikasinya

Klik

```
https://app-LGZE0Z2UY4NZ.mlflow.sagemaker.us-east-1.app.aws/auth?  
authToken=eyJhbGciOiJIUzI1NiJ9.eyJhdXRoVG9rZW5JZCI6IkxETVBPUyIsImZhc0NyZWRLbnRpYWxzIjoiaWdWNGhD
```

Tampilan




Lanjutkan ke resep di bawah blok run SageMaker HyperPod resep Anda

Resep

```
run
  mlflow_tracking_uri: arn:aws:sagemaker:us-east-1:111122223333:mlflow-app/app-
  LGZE0Z2UY4NZ
```

Tampilan



Pelatihan Iteratif

Ikhtisar

Pelatihan berulang adalah proses menyempurnakan model berulang kali melalui beberapa siklus pelatihan di berbagai metode pelatihan — melatih, mengevaluasi, menganalisis kesalahan, menyesuaikan data/objectives/hyperparameters — dengan setiap putaran dimulai dari pos pemeriksaan sebelumnya. Pendekatan ini memungkinkan Anda untuk secara sistematis menargetkan mode kegagalan model, menggabungkan contoh yang dikuratori untuk mengatasi kelemahan tertentu, dan beradaptasi dengan perubahan persyaratan dari waktu ke waktu.

Manfaat dibandingkan pelatihan single-pass:

- Peningkatan yang ditargetkan: Mengatasi pola kegagalan spesifik yang ditemukan melalui evaluasi
- Penyempurnaan adaptif: Menanggapi pergeseran distribusi atau persyaratan produk yang berkembang
- Mitigasi risiko: Validasi perbaikan secara bertahap daripada berkomitmen pada satu kali pelatihan jangka panjang
- Efisiensi data: Fokuskan upaya pengumpulan data pada area di mana model berkinerja buruk
- Pelatihan Kurikulum: Beberapa putaran pelatihan dengan kualitas data yang semakin tinggi

Cara kerjanya

Lokasi dan akses pos pemeriksaan

Setelah setiap pekerjaan pelatihan selesai, file manifes dihasilkan di lokasi keluaran yang ditentukan oleh `output_path` parameter dalam konfigurasi pelatihan Anda.

Untuk mengakses pos pemeriksaan Anda

- Arahkan ke yang Anda tentukan `output_path` di S3
- Unduh dan ekstrak `output.tar.gz` file
- Buka `manifest.json` file di dalamnya
- Temukan `checkpoint_s3_bucket` parameter, yang berisi URI S3 dari model terlatih Anda

Contoh struktur `manifest.json`

```
{
  "checkpoint_s3_bucket": "s3://customer-escrow-<account-number>-smtj-<unique-
  identifier>/<job-name>/stepID",
  ...
}
```

Memahami ember escrow

Karena bobot Amazon Nova adalah hak milik, pos pemeriksaan model terlatih disimpan dalam bucket S3 escrow dalam akun yang AWS dikelola daripada disalin ke akun Anda. Ember escrow ini:

- Berisi bobot model khusus Anda dengan aman

- Dapat direferensikan oleh AWS layanan lain (Inferensi, Evaluasi, dan pekerjaan pelatihan berikutnya)
- Hanya dapat diakses ke AWS akun Anda melalui izin IAM
- Menimbulkan biaya penyimpanan S3 standar di akun Anda (lihat Pertimbangan biaya)

Anda dapat menggunakan jalur keranjang escrow seperti `model_name_or_path` dalam latihan Anda berikutnya untuk melanjutkan pelatihan berulang.

Menggunakan pos pemeriksaan untuk pelatihan berulang

Konfigurasi tugas pelatihan Anda berikutnya untuk menggunakan pos pemeriksaan sebelumnya sebagai model dasar:

```
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
```

Kapan harus menggunakan pelatihan berulang

Kasus penggunaan yang ideal

Gunakan pelatihan berulang ketika Anda memiliki:

- Loop umpan balik — Kemampuan untuk mengumpulkan kasus kegagalan dunia nyata dan mengatasinya secara sistematis
- Lingkungan dinamis - Dokumentasi yang berkembang, APIs, atau topik pendukung yang membutuhkan pembaruan model berkala
- Evaluasi yang kuat - Tolok ukur yang kuat dan kerangka evaluasi (lihat contoh di bawah) untuk mengukur peningkatan dengan percaya diri
- Kemampuan operasi ML - Sumber daya untuk mengelola beberapa siklus pelatihan dan kontrol versi

Contoh kerangka evaluasi yang kuat

- Suite benchmark otomatis dengan pass/fail ambang batas
- Protokol evaluasi manusia dengan metrik reliabilitas antar-penilai
- Skenario pengujian tim merah yang mencakup kasus tepi dan input permusuhan
- Infrastruktur pengujian A/B untuk mengukur dampak produksi

Pola umum

SFT → RFT Pipeline: Pola iteratif yang sering digunakan melibatkan:

- SFT pertama — Ajarkan model bagaimana memecahkan masalah melalui contoh demonstrasi
- RFT kedua - Optimalkan kinerja di seluruh ruang masalah yang lebih luas menggunakan sinyal hadiah

Urutan ini penting ketika model berkinerja buruk pada awalnya — RFT pada model akurasi mendekati nol tidak akan meningkatkan kinerja tanpa terlebih dahulu menetapkan kemampuan pemecahan masalah dasar melalui SFT.

Kapan tidak menggunakan pelatihan berulang

Hindari pelatihan berulang untuk:

- Tugas yang stabil dan terdefinisi dengan baik — Data stasioner dengan persyaratan konsisten yang sudah mencapai kinerja mendekati langit-langit
- Masalah klasifikasi sederhana — Tugas sempit di mana pelatihan single-pass cukup
- Kendala sumber daya - Kurangnya kemampuan operasi ML khusus untuk mengelola beberapa siklus pelatihan
- Keuntungan marjinal - Ketika overhead tidak membenarkan peningkatan kinerja minimal

Contoh alur kerja: SFT → RFT

Contoh ini menunjukkan pola pelatihan berulang yang umum untuk model penalaran.

Langkah 1: Pelatihan SFT awal

Konfigurasi dan luncurkan pekerjaan pelatihan SFT Anda dengan kumpulan data Anda:

```
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
```

Alasan: SFT menyediakan demonstrasi tambahan yang membentuk output model ke dalam format dan suara yang Anda inginkan, membangun kemampuan dasar.

Setelah pelatihan selesai

- Perhatikan `output_path` konfigurasi dalam pekerjaan pelatihan Anda
- Download `output.tar.gz` dari lokasi tersebut
- Ekstrak dan temukan `manifest.json`
- Salin `checkpoint_s3_bucket` nilainya

Langkah 2: Pelatihan RFT di pos pemeriksaan SFT

Buat pekerjaan pelatihan RFT baru menggunakan pos pemeriksaan SFT:

```
run:
  name: "rft-on-sft-checkpoint"
  model_type: amazon.nova-2-lite-v1:0:256k
  model_name_or_path: "s3://customer-escrow-<account-number>-smtj-<unique-identifier>/<initial-sft-training>"
  data_s3_path: s3://<bucket>/rft-training-data.jsonl
  reward_lambda_arn: <your-reward-function-arn>
```

Alasan: Pelatihan RFT dibangun di atas fondasi SFT, memungkinkan model untuk mengembangkan pola penalaran yang lebih kompleks yang dioptimalkan oleh fungsi hadiah Anda.

Langkah 3: Evaluasi dan iterasi

Jalankan evaluasi di pos pemeriksaan RFT untuk menilai kinerja:

```
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
```

Jika metrik target tidak terpenuhi, lanjutkan iterasi dengan data atau hiperparameter yang disesuaikan.

Important

Teknik pelatihan (LoRa vs Peringkat Penuh) harus tetap konsisten di semua iterasi:

- Jika Anda menggunakan SFT dengan LoRa, Anda harus menggunakan RFT dengan LoRa
- Jika Anda menggunakan SFT dengan Peringkat Penuh, Anda harus menggunakan RFT dengan Peringkat Penuh
- Anda tidak dapat beralih antara Pipa tengah LoRa dan Peringkat Penuh

Important

Jika kunci KMS digunakan untuk enkripsi di bucket S3 keluaran milik Amazon, kunci KMS yang sama harus digunakan untuk semua iterasi future.

Memantau kemajuan di seluruh iterasi

Anda dapat melacak metrik MLflow melalui [pengaturan MLflow](#) untuk pekerjaan Anda.

Buat MLflow aplikasi

Menggunakan UI Studio: Jika Anda membuat pekerjaan pelatihan melalui UI Studio, MLflow aplikasi default dibuat secara otomatis dan dipilih secara default di bawah Opsi Lanjutan.

Menggunakan CLI: Jika Anda menggunakan CLI, Anda harus membuat MLflow aplikasi dan meneruskannya sebagai input ke permintaan API pekerjaan pelatihan.

```
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)
```

Akses MLflow aplikasinya

Menggunakan CLI: Buat URL yang telah ditentukan sebelumnya untuk mengakses UI aplikasi: MLflow

```
aws sagemaker create-presigned-mlflow-app-url \  
  --arn $mlflow_app_arn \  
  --region $region \  
  --output text
```

Menggunakan UI Studio: UI Studio menampilkan metrik kunci yang disimpan MLflow dan menyediakan tautan ke UI MLflow aplikasi.

Metrik kunci untuk dilacak

Pantau metrik ini di seluruh iterasi untuk menilai peningkatan dan melacak kemajuan pekerjaan:

Untuk SFT

- Kurva kehilangan pelatihan
- Jumlah sampel yang dikonsumsi dan waktu untuk memproses sampel
- Akurasi kinerja pada set uji yang diheld-out
- Kepatuhan format (misalnya, tingkat keluaran JSON yang valid)
- Kebingungan pada data evaluasi khusus domain

Untuk RFT

- Skor hadiah rata-rata selama pelatihan
- Distribusi hadiah (persentase respons hadiah tinggi)
- Tren hadiah validasi (perhatikan overfitting)
- Tingkat keberhasilan khusus tugas (misalnya, tingkat kelulusan eksekusi kode, akurasi masalah matematika)

Umum

- Delta kinerja benchmark antara iterasi
- Skor evaluasi manusia pada sampel yang representatif
- Metrik produksi (jika menerapkan secara berulang)

Menentukan kapan harus berhenti

Berhenti iterasi saat:

- Dataran tinggi kinerja - Pelatihan tambahan tidak lagi meningkatkan metrik target secara bermakna
- Peralihan teknik membantu — Jika salah satu teknik mencapai puncak, coba beralih (misalnya, SFT → RFT → SFT) untuk menerobos langit-langit kinerja
- Metrik target tercapai - Kriteria keberhasilan Anda terpenuhi
- Regresi terdeteksi - Iterasi baru menurunkan kinerja (lihat prosedur rollback di bawah)

Untuk prosedur evaluasi terperinci, lihat bagian Evaluasi.

Praktik terbaik

Mulai dari yang kecil dan skala secara bertahap

Mulailah dengan kumpulan data minimal dan periode pelatihan tunggal untuk memvalidasi pendekatan Anda sebelum meningkatkan skala. Ini membangun kepercayaan diri dan membantu mengidentifikasi masalah sejak dini.

Menetapkan metrik keberhasilan yang jelas

Tentukan indikator kuantitatif dan kualitatif sebelum memulai:

Contoh metrik keberhasilan berdasarkan kasus penggunaan

- Menjawab pertanyaan — Akurasi kecocokan yang tepat, skor F1, peringkat preferensi manusia
- Pembuatan kode - Tingkat kelulusan pengujian unit, keberhasilan kompilasi, waktu eksekusi
- Tugas penalaran — Akurasi langkah, kebenaran jawaban akhir, skor hadiah
- Pembuatan konten - Skor koherensi, akurasi faktual, kepatuhan gaya

Menerapkan evaluasi otomatis

Siapkan jalur evaluasi otomatis untuk melacak kinerja setelah setiap putaran, memungkinkan iterasi cepat dan perbandingan objektif.

Pertahankan kontrol versi yang ketat

Dokumen untuk setiap iterasi:

- Versi dan modifikasi dataset
- Model lokasi pos pemeriksaan
- Perubahan hyperparameter
- Metrik kinerja dan delta
- Pengamatan kualitatif

Ini membangun pengetahuan kelembagaan dan memungkinkan debugging.

Fokus pada kualitas data daripada kuantitas

Analisis kasus kegagalan dari putaran sebelumnya dan tambahkan contoh berkualitas tinggi yang ditargetkan daripada hanya meningkatkan ukuran kumpulan data.

Rencanakan anggaran iterasi

Rencanakan 3-5 iterasi sebagai rentang tipikal:

- 1-2 iterasi — Seringkali cukup untuk perbaikan sederhana atau pemolesan akhir
- 3-5 iterasi — Sesuai untuk tugas-tugas kompleks yang membutuhkan beberapa siklus penyempurnaan
- 5+ iterasi — Dapat menunjukkan pengembalian yang berkurang atau kebutuhan untuk pendekatan yang berbeda

Sesuaikan berdasarkan anggaran komputasi dan tingkat peningkatan kinerja.

Menerapkan kemampuan rollback

Jika iterasi memperkenalkan regresi:

- Identifikasi regresi — Bandingkan metrik evaluasi di seluruh pos pemeriksaan

- Kembali ke pos pemeriksaan sebelumnya - Gunakan jalur S3 pos pemeriksaan sebelumnya sebagai milik Anda `model_name_or_path`
- Sesuaikan pendekatan pelatihan — Ubah data, hiperparameter, atau teknik sebelum mencoba lagi
- Dokumentasikan kegagalan — Catat apa yang menyebabkan regresi untuk menghindari pengulangan

Contoh rollback

```
run:
  name: "rollback-to-iteration-2"
  model_type: amazon.nova-2-lite-v1:0:256k
  # Use iteration 2 checkpoint instead of failed iteration 3
  model_name_or_path: "s3://customer-escrow-<account-number>-smtj-<unique-identifier>/<iteration-2-job-name>"
```

Pertimbangan Biaya

Penyimpanan pos pemeriksaan

- Lokasi - Pos pemeriksaan yang disimpan dalam ember escrow dikenakan biaya penyimpanan S3 standar yang ditagih ke akun Anda AWS
- Retensi - Pos pemeriksaan dipertahankan tanpa batas kecuali dihapus secara eksplisit
- Manajemen - Menerapkan kebijakan siklus hidup untuk mengarsipkan atau menghapus pos pemeriksaan lama yang tidak lagi Anda perlukan

Kiat pengoptimalan biaya

- Hapus pos pemeriksaan menengah setelah memvalidasi iterasi yang lebih baru
- Arsipkan pos pemeriksaan ke S3 Glacier untuk retensi jangka panjang dengan biaya lebih rendah
- Tetapkan kebijakan retensi berdasarkan kepatuhan dan kebutuhan eksperimen

Batasan

Konsistensi keluarga model

Saat pelatihan berulang, Anda harus menggunakan jenis model yang sama di semua iterasi.

Pelatihan awal

```
run:
  model_type: amazon.nova-2-lite-v1:0:256k
  model_name_or_path: "nova-lite-2/prod"
```

Iterasi berikutnya harus menggunakan `model_type` yang sama

```
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>"
```

Konsistensi teknik pelatihan

Teknik pelatihan harus tetap konsisten di seluruh iterasi:

- Model yang dilatih Lora hanya dapat dilatih secara iteratif dengan LoRa
- Full-Rank-trained model hanya dapat dilatih secara iteratif dengan Full-Rank

Bagaimana adaptor LoRa bekerja dalam pelatihan berulang

- Setiap iterasi pelatihan LoRa menghasilkan bobot adaptor baru
- Adaptor baru mengganti (bukan tumpukan dengan) adaptor sebelumnya
- Model dasar tetap beku; hanya adaptor yang diperbarui

Matriks kompatibilitas teknik

Pelatihan awal	Dapat iterasi dengan
SFT (Peringkat Penuh)	SFT (Peringkat Penuh), RFT (Peringkat Penuh)
SFT (LoRa)	SFT (LoRa), RFT (LoRa)
RFT (Peringkat Penuh)	RFT (Peringkat Penuh)
RFT (LoRa)	RFT (LoRa)

Memverifikasi kompatibilitas sebelum memulai pekerjaan

- Periksa resep pelatihan Anda sebelumnya untuk mengidentifikasi jenis model dan teknik pelatihan (LoRa vs Peringkat Penuh)
- Pastikan resep baru Anda cocok dengan jenis model dan teknik
- Tinjau manifest.json untuk mengonfirmasi jalur pos pemeriksaan sudah benar

Pemecahan masalah

Kesalahan: “Teknik pelatihan model yang tidak kompatibel terdeteksi”

Penyebab: Teknik pelatihan (LoRa vs Peringkat Penuh) tidak cocok dengan teknik pos pemeriksaan.

Resolusi: Pastikan resep Anda menggunakan teknik pelatihan yang sama dengan model aslinya:

- Jika pos pemeriksaan dilatih dengan LoRa, gunakan LoRa dalam resep baru Anda
- Jika pos pemeriksaan dilatih dengan Peringkat Penuh, gunakan Peringkat Penuh dalam resep baru Anda

Kesalahan: “Model dasar untuk pekerjaan yang diekstrak dari model_name_or_path tidak cocok dengan model_type”

Penyebab: Jenis model yang ditentukan model_type tidak cocok dengan model sebenarnya di pos pemeriksaan.

Resolusi: Verifikasi bahwa:

- model_type Dalam resep Anda cocok dengan jenis model asli
- Jalur pos pemeriksaan S3 sudah benar model_name_or_path
- Anda menggunakan jalur dari file manifest.json yang benar

Contoh konfigurasi yang benar

```
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>"
```

Kesalahan: “Konfigurasi model tidak ditemukan”

Penyebab: Jalur S3 tidak valid atau `model_name_or_path` tidak dapat diakses.

Resolusi:

- Verifikasi jalur S3 disalin dengan benar dari file `manifest.json`
- Pastikan peran IAM Anda memiliki izin untuk mengakses keranjang escrow
- Konfirmasikan pekerjaan pelatihan sebelumnya berhasil diselesaikan
- Periksa kesalahan ketik di jalur

Regresi kinerja setelah iterasi

Gejala: Metrik evaluasi menurun setelah iterasi pelatihan baru.

Resolusi:

- Rollback - Gunakan pos pemeriksaan sebelumnya sebagai model dasar Anda
- Analisis — Meninjau log pelatihan dan kualitas data untuk iterasi yang gagal
- Sesuaikan — Ubah hiperparameter (kurangi tingkat pembelajaran), tingkatkan kualitas data, atau kurangi zaman pelatihan
- Coba lagi - Luncurkan iterasi baru dengan penyesuaian

SageMaker Inferensi

Model Amazon Nova khusus sekarang tersedia pada SageMaker inferensi. Dengan Amazon Nova aktif SageMaker, Anda dapat mulai mendapatkan prediksi, atau kesimpulan, dari model Amazon Nova kustom Anda yang terlatih. SageMaker menyediakan berbagai pilihan infrastruktur dan opsi penerapan model ML untuk membantu memenuhi semua kebutuhan inferensi ML Anda. Dengan SageMaker inferensi, Anda dapat menskalakan penerapan model Anda, mengelola model secara lebih efektif dalam produksi, dan mengurangi beban operasional.

SageMaker memberi Anda berbagai opsi inferensi, seperti titik akhir waktu nyata untuk mendapatkan inferensi latensi rendah, dan titik akhir asinkron untuk kumpulan permintaan. Dengan memanfaatkan opsi inferensi yang sesuai untuk kasus penggunaan Anda, Anda dapat memastikan penerapan dan inferensi model yang efisien. Untuk informasi lebih lanjut tentang SageMaker inferensi, lihat [Menerapkan model untuk inferensi](#).

 Important

Hanya model kustom peringkat penuh dan model gabungan LoRa yang didukung pada inferensi. SageMaker Untuk model LoRa yang tidak digabungkan dan model dasar, gunakan Amazon Bedrock.

Fitur

Fitur-fitur berikut tersedia untuk model Amazon Nova pada SageMaker inferensi:

Kemampuan Model

- Pembuatan teks

Penerapan dan Penskalaan

- Titik akhir real-time dengan pemilihan instans khusus
- Auto Scaling — Secara otomatis menyesuaikan kapasitas berdasarkan pola lalu lintas untuk mengoptimalkan biaya dan pemanfaatan GPU. Untuk informasi selengkapnya, lihat [Menskalakan SageMaker Model Amazon secara otomatis](#).
- Dukungan API streaming untuk pembuatan token waktu nyata

Pemantauan dan Optimalisasi

- CloudWatch Integrasi Amazon untuk pemantauan dan peringatan
- Ketersediaan Optimalisasi latensi sadar zona melalui konfigurasi VPC

Alat Pengembangan

- AWS CLI dukungan - Untuk informasi selengkapnya, lihat [Referensi Perintah AWS CLI](#) untuk SageMaker
- Integrasi notebook melalui dukungan SDK

Model dan instance yang didukung

Saat membuat titik akhir SageMaker inferensi, Anda dapat mengatur dua variabel lingkungan untuk mengonfigurasi penerapan: `CONTEXT_LENGTH` dan `MAX_CONCURRENCY`

- `CONTEXT_LENGTH`— Total panjang token maksimum (input+output) per permintaan
- `MAX_CONCURRENCY`— Jumlah maksimum permintaan bersamaan yang akan dilayani titik akhir

Tabel berikut mencantumkan model Amazon Nova yang didukung, jenis instans, dan konfigurasi yang didukung. Nilai `MAX_CONCURRENCY` mewakili konkurensi maksimum yang didukung untuk setiap pengaturan `CONTEXT_LENGTH`:

Model	Tipe Instans	Konfigurasi yang Didukung
Amazon Nova Mikro	ml.g5.12xbesar	CONTEXT_LENGTH: 4000, MAX_CONCURRENCY: 32 CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 16
	ml.g5.24xbesar	CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 32
	ml.g6.12xlarge	CONTEXT_LENGTH: 4000, MAX_CONCURRENCY: 32 CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 16
	ml.g6.24xbesar	CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 32
	ml.g6.48xlarge	CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 32
	ml.p5.48xbesar	CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 32

Model	Tipe Instans	Konfigurasi yang Didukung
Amazon Nova Lite		CONTEXT_LENGTH: 16000, MAX_CONCURRENCY: 2
		CONTEXT_LENGTH: 24000, MAX_CONCURRENCY: 1
	ml.g6.48xlarge	CONTEXT_LENGTH: 4000, MAX_CONCURRENCY: 32
		CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 16
Nova 2 Lite	ml.p5.48xbesar	CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 32
		CONTEXT_LENGTH: 16000, MAX_CONCURRENCY: 2
		CONTEXT_LENGTH: 24000, MAX_CONCURRENCY: 1
Nova 2 Lite	ml.p5.48xbesar	CONTEXT_LENGTH: 8000, MAX_CONCURRENCY: 32
		CONTEXT_LENGTH: 16000, MAX_CONCURRENCY: 2
		CONTEXT_LENGTH: 24000, MAX_CONCURRENCY: 1

Note

Nilai MAX_CONCURRENCY yang ditampilkan adalah batas atas untuk setiap pengaturan CONTEXT_LENGTH. Anda dapat menggunakan panjang konteks yang lebih rendah dengan konkurensi yang sama, tetapi melebihi nilai ini akan menyebabkan pembuatan SageMaker titik akhir gagal.

Misalnya, di Amazon Nova Micro dengan ml.g5.12xlarge:

- CONTEXT_LENGTH=2000, MAX_CONCURRENCY=32 → Berlaku
- CONTEXT_LENGTH=8000, MAX_CONCURRENCY=32 → Ditolak (batas konkurensi adalah 16 pada panjang konteks 8000)
- CONTEXT_LENGTH=8000, MAX_CONCURRENCY=4 → Berlaku
- CONTEXT_LENGTH=8000, MAX_CONCURRENCY=16 → Berlaku
- CONTEXT_LENGTH=10000 → Ditolak (panjang konteks maks adalah 8000 pada contoh ini)

AWS Wilayah yang Didukung

Tabel berikut mencantumkan AWS Wilayah tempat model Amazon Nova tersedia pada SageMaker inferensi:

Nama wilayah	Kode Wilayah	Ketersediaan
US East (Northern Virginia)	us-east-1	Available
AS Barat (Oregon)	us-west-2	Available

Gambar Kontainer yang Didukung

Tabel berikut mencantumkan gambar kontainer URIs untuk model Amazon Nova pada SageMaker inferensi berdasarkan wilayah. Dua tag gambar tersedia untuk setiap wilayah: tag berversi (v1.0.0) dan tag terbaru (SM-Inference-latest). Untuk penerapan produksi, sebaiknya gunakan tag berversi.

Region	Gambar Kontainer URIs
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

Praktik Terbaik

Untuk praktik terbaik dalam menerapkan dan mengelola model SageMaker, lihat [Praktik Terbaik untuk SageMaker](#).

Support

Untuk masalah dan dukungan dengan model Amazon Nova pada SageMaker inferensi, hubungi AWS Support melalui Konsol atau manajer AWS akun Anda.

Topik

- [Memulai](#)
- [Referensi API](#)
- [Evaluasi Model yang Dihosting pada SageMaker Inferensi](#)
- [Penyebaran Model Amazon Nova Forge di deteksi penyalahgunaan SageMaker Inferensi Amazon](#)

Memulai

Panduan ini menunjukkan cara menerapkan model Amazon Nova yang disesuaikan pada titik akhir SageMaker waktu nyata, mengonfigurasi parameter inferensi, dan memanggil model Anda untuk pengujian.

Prasyarat

Berikut ini adalah prasyarat untuk menerapkan model Amazon Nova pada inferensi: SageMaker

- Buat Akun AWS - Jika Anda belum memilikinya, lihat [Membuat AWS akun](#).
- Izin IAM yang diperlukan - Pastikan pengguna atau peran IAM Anda memiliki kebijakan terkelola berikut ini terlampir:
 - AmazonSageMakerFullAccess
 - AmazonS3FullAccess
- SDKs/CLI Versi yang diperlukan - Versi SDK berikut telah diuji dan divalidasi dengan model Amazon Nova pada SageMaker inferensi:
 - SageMaker Python SDK v3.0.0+ () untuk pendekatan API berbasis sumber daya
`sagemaker>=3.0.0`

- Boto3 versi 1.35.0+ () `boto3>=1.35.0` untuk panggilan API langsung. Contoh dalam panduan ini menggunakan pendekatan ini.
- Peningkatan kuota layanan - Minta peningkatan kuota SageMaker layanan Amazon untuk jenis instans ML yang akan digunakan untuk titik akhir SageMaker Inferensi (misalnya, `m1.p5.48xlarge` for endpoint usage Untuk daftar tipe instans yang didukung, lihat [the section called “Model dan instance yang didukung”](#). Untuk meminta kenaikan, lihat [Meminta kenaikan kuota](#). Untuk informasi tentang kuota SageMaker instance, lihat [SageMaker titik akhir dan kuota](#).

Langkah 1: Konfigurasi AWS kredensial

Konfigurasi AWS kredensial Anda menggunakan salah satu metode berikut:

Opsi 1: AWS CLI (Disarankan)

```
aws configure
```

Masukkan kunci AWS akses, kunci rahasia, dan wilayah default Anda saat diminta.

Opsi 2: file AWS kredensial

Buat atau edit `~/.aws/credentials`:

```
[default]
aws_access_key_id = YOUR_ACCESS_KEY
aws_secret_access_key = YOUR_SECRET_KEY
```

Opsi 3: Variabel lingkungan

```
export AWS_ACCESS_KEY_ID=your_access_key
export AWS_SECRET_ACCESS_KEY=your_secret_key
```

Note

Untuk informasi selengkapnya tentang AWS kredensial, lihat [Konfigurasi dan setelan file kredensial](#).

Inisialisasi klien AWS

Buat skrip atau buku catatan Python dengan kode berikut untuk menginisialisasi AWS SDK dan memverifikasi kredensialmu:

```
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.")
```

Jika otentikasi berhasil, Anda akan melihat output yang mengonfirmasi ID AWS akun Anda.

Langkah 2: Buat peran SageMaker eksekusi

Peran SageMaker eksekusi adalah peran IAM yang memberikan SageMaker izin untuk mengakses AWS sumber daya atas nama Anda, seperti bucket Amazon S3 untuk artefak model dan untuk pencatatan. CloudWatch

Membuat peran eksekusi

Note

Membuat peran IAM membutuhkan `iam:CreateRole` dan `iam:AttachRolePolicy` izin. Pastikan pengguna atau peran IAM Anda memiliki izin ini sebelum melanjutkan.

Kode berikut membuat peran IAM dengan izin yang diperlukan untuk menerapkan model khusus Amazon Nova:

```
import json

# Create SageMaker Execution Role
role_name = f"SageMakerInference-ExecutionRole-{AWS_ACCOUNT_ID}"

trust_policy = {
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Principal": {"Service": "sagemaker.amazonaws.com"},
            "Action": "sts:AssumeRole"
        }
    ]
}

iam = boto3.client('iam', region_name=REGION)

# Create the role
role_response = iam.create_role(
    RoleName=role_name,
    AssumeRolePolicyDocument=json.dumps(trust_policy),
    Description='SageMaker execution role with S3 and SageMaker access'
)

# Attach required policies
iam.attach_role_policy(
    RoleName=role_name,
    PolicyArn='arn:aws:iam::aws:policy/AmazonSageMakerFullAccess'
)

iam.attach_role_policy(
    RoleName=role_name,
    PolicyArn='arn:aws:iam::aws:policy/AmazonS3FullAccess'
)

SAGEMAKER_EXECUTION_ROLE_ARN = role_response['Role']['Arn']
print(f"Created SageMaker execution role: {SAGEMAKER_EXECUTION_ROLE_ARN}")
```

Menggunakan peran eksekusi yang ada (Opsional)

Jika Anda sudah memiliki peran SageMaker eksekusi, Anda dapat menggunakannya sebagai gantinya:

```
# Replace with your existing role ARN
SAGEMAKER_EXECUTION_ROLE_ARN = "arn:aws:iam::YOUR_ACCOUNT_ID:role/
YOUR_EXISTING_ROLE_NAME"
```

Untuk menemukan SageMaker peran yang ada di akun Anda:

```
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

Peran eksekusi harus memiliki hubungan kepercayaan dengan `sagemaker.amazonaws.com` dan izin untuk mengakses Amazon S3 SageMaker dan sumber daya.

Untuk informasi selengkapnya tentang peran SageMaker eksekusi, lihat [SageMaker Peran](#).

Langkah 3: Konfigurasi parameter model

Konfigurasi parameter penerapan untuk model Amazon Nova Anda. Pengaturan ini mengontrol perilaku model, alokasi sumber daya, dan karakteristik inferensi. Untuk daftar jenis instance yang didukung dan nilai `CONTEXT_LENGTH` dan `MAX_CONCURRENCY` yang didukung untuk masing-masing, lihat [the section called “Model dan instance yang didukung”](#)

Parameter yang diperlukan

- **IMAGE:** URI gambar kontainer Docker untuk wadah inferensi Amazon Nova. Ini akan disediakan oleh AWS.
- **CONTEXT_LENGTH:** Panjang konteks model.

- **MAX_CONCURRENCY:** Jumlah maksimum urutan per iterasi; menetapkan batas pada berapa banyak permintaan pengguna individu (prompt) dapat diproses secara bersamaan dalam satu batch pada GPU. Rentang: bilangan bulat lebih besar dari 0.

Parameter generasi opsional

- **DEFAULT_TEMPERATURE:** Mengontrol keacakan dalam generasi. Rentang: 0,0 hingga 2,0 (0,0 = deterministik, lebih tinggi = lebih acak).
- **DEFAULT_TOP_P:** Ambang pengambilan sampel nukleus untuk pemilihan token. Rentang: 1e-10 hingga 1.0.
- **DEFAULT_TOP_K:** Membatasi pemilihan token ke token K teratas yang paling mungkin. Rentang: bilangan bulat -1 atau lebih besar (-1 = tidak ada batas).
- **DEFAULT_MAX_NEW_TOKENS:** Jumlah maksimum token yang akan dihasilkan sebagai respons (yaitu token keluaran maks). Rentang: bilangan bulat 1 atau lebih besar.
- **DEFAULT_LOGPROBS:** Jumlah probabilitas log untuk dikembalikan per token. Rentang: bilangan bulat 1 hingga 20.

Konfigurasi penerapan Anda

```
# 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}")

```

Konfigurasi parameter khusus penerapan

Sekarang konfigurasi parameter spesifik untuk penerapan model Amazon Nova Anda, termasuk lokasi artefak model dan pemilihan jenis instans.

Tetapkan pengenalan penerapan

```

# Deployment identifier - use a descriptive name for your use case
JOB_NAME = "my-nova-deployment"

```

Tentukan lokasi artefak model

Sediakan URI Amazon S3 tempat artefak model Amazon Nova terlatih Anda disimpan. Ini harus menjadi lokasi keluaran dari pelatihan model atau pekerjaan fine-tuning Anda.

```

# 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/"
```

Pilih varian model dan tipe instance

```
# 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}")
```

Konvensi penamaan

Kode secara otomatis menghasilkan nama yang konsisten untuk AWS sumber daya:

- Nama model: {JOB_NAME}-{model}-{instance-type}
- Konfigurasi Titik Akhir: {MODEL_NAME}-Config
- Nama titik akhir: {MODEL_NAME}-Endpoint

Langkah 4: Buat konfigurasi SageMaker model dan titik akhir

Pada langkah ini, Anda akan membuat dua sumber daya penting: objek SageMaker model yang mereferensikan artefak model Amazon Nova Anda, dan konfigurasi titik akhir yang menentukan bagaimana model akan digunakan.

SageMaker Model: Objek model yang mengemas gambar kontainer inferensi, lokasi artefak model, dan konfigurasi lingkungan. Ini adalah sumber daya yang dapat digunakan kembali yang dapat digunakan ke beberapa titik akhir.

Konfigurasi Titik Akhir: Mendefinisikan setelan infrastruktur untuk penerapan, termasuk jenis instans, jumlah instance, dan varian model. Ini memungkinkan Anda untuk mengelola pengaturan penerapan secara terpisah dari model itu sendiri.

Buat SageMaker model

Kode berikut membuat SageMaker model yang mereferensikan artefak model Amazon Nova Anda:

```
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}")
```

Parameter kunci:

- **ModelName:** Pengidentifikasi unik untuk model Anda
- **Image:** URI gambar wadah Docker untuk inferensi Amazon Nova
- **ModelDataSource:** Lokasi Amazon S3 dari artefak model Anda
- **Environment:** Variabel lingkungan dikonfigurasi pada Langkah 3
- **ExecutionRoleArn:** Peran IAM dari Langkah 2
- **EnableNetworkIsolation:** Setel ke True untuk keamanan yang ditingkatkan (mencegah kontainer melakukan panggilan jaringan keluar)

Buat konfigurasi titik akhir

Selanjutnya, buat konfigurasi endpoint yang mendefinisikan infrastruktur deployment Anda:

```
# 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}")
```

Parameter kunci:

- **VariantName:** Pengidentifikasi untuk varian model ini (gunakan 'primer' untuk penerapan model tunggal)
- **ModelName:** Referensi model yang dibuat di atas
- **InitialInstanceCount:** Jumlah instance yang akan diterapkan (mulai dengan 1, skala nanti jika diperlukan)
- **InstanceType:** Jenis contoh ML dipilih pada Langkah 3

Verifikasi pembuatan sumber daya

Anda dapat memverifikasi bahwa sumber daya Anda berhasil dibuat:

```
# 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")
```

Langkah 5: Menyebarkan titik akhir

Langkah selanjutnya adalah menerapkan model Amazon Nova Anda dengan membuat titik akhir waktu SageMaker nyata. Titik akhir ini akan meng-host model Anda dan menyediakan titik akhir HTTPS yang aman untuk membuat permintaan inferensi.

Pembuatan titik akhir biasanya memakan waktu 15-30 menit untuk menyediakan AWS infrastruktur, mengunduh artefak model Anda, dan menginisialisasi wadah inferensi.

Buat titik akhir

```
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}")
```

Pantau pembuatan titik akhir

Kode berikut akan melakukan polling status endpoint hingga penerapan selesai:

```
# 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

```

Verifikasi titik akhir sudah siap

Setelah titik akhir InService, Anda dapat memverifikasi konfigurasinya:

```

# 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
```

Memecahkan masalah kegagalan pembuatan titik akhir

Alasan kegagalan umum:

- Kapasitas tidak mencukupi: Jenis instans yang diminta tidak tersedia di wilayah Anda
 - Solusi: Coba jenis instans yang berbeda atau minta peningkatan kuota
- Izin IAM: Peran eksekusi tidak memiliki izin yang diperlukan
 - Solusi: Verifikasi peran memiliki akses ke artefak model Amazon S3 dan izin yang diperlukan SageMaker
- Artefak model tidak ditemukan: URI Amazon S3 salah atau tidak dapat diakses
 - Solusi: Verifikasi URI Amazon S3 dan periksa izin bucket, pastikan Anda berada di wilayah yang benar
- Batas sumber daya: Batas akun terlampaui untuk titik akhir atau instance
 - Solusi: Minta peningkatan kuota layanan melalui Service AWS Quotas atau Support

Note

Jika Anda perlu menghapus titik akhir yang gagal dan memulai dari awal:

```
sagemaker.delete_endpoint(EndpointName=ENDPOINT_NAME)
```

Langkah 6: Panggil titik akhir

Setelah titik akhir Anda InService, Anda dapat mengirim permintaan inferensi untuk menghasilkan prediksi dari model Amazon Nova Anda. SageMaker mendukung titik akhir sinkron (real-time dengan mode streaming/non-streaming) dan titik akhir asinkron (berbasis Amazon S3 untuk pemrosesan batch).

Siapkan klien runtime

Buat klien SageMaker Runtime dengan pengaturan batas waktu yang sesuai:

```
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)
```

Buat fungsi inferensi universal

Fungsi berikut menangani permintaan streaming dan non-streaming:

```
def invoke_nova_endpoint(request_body):
    """
    Invoke Nova endpoint with automatic streaming detection.

    Args:
        request_body (dict): Request payload containing prompt and parameters

    Returns:
        dict: Response from the model (for non-streaming requests)
        None: For streaming requests (prints output directly)
    """
    body = json.dumps(request_body)
    is_streaming = request_body.get("stream", False)

    try:
        print(f"Invoking endpoint ({'streaming' if is_streaming else 'non-streaming'})...")

        if is_streaming:
            response = runtime_client.invoke_endpoint_with_response_stream(
```

```

        EndpointName=ENDPOINT_NAME,
        ContentType='application/json',
        Body=body
    )

    event_stream = response['Body']
    for event in event_stream:
        if 'PayloadPart' in event:
            chunk = event['PayloadPart']
            if 'Bytes' in chunk:
                data = chunk['Bytes'].decode()
                print("Chunk:", data)
    else:
        # Non-streaming inference
        response = runtime_client.invoke_endpoint(
            EndpointName=ENDPOINT_NAME,
            ContentType='application/json',
            Accept='application/json',
            Body=body
        )

        response_body = response['Body'].read().decode('utf-8')
        result = json.loads(response_body)
        print("# Response received successfully")
        return result

except ClientError as e:
    error_code = e.response['Error']['Code']
    error_message = e.response['Error']['Message']
    print(f"# AWS Error: {error_code} - {error_message}")
except Exception as e:
    print(f"# Unexpected error: {str(e)}")

```

Contoh 1: Penyelesaian obrolan non-streaming

Gunakan format obrolan untuk interaksi percakapan:

```

# 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)

```

Sampel respon:

```

{
  "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
}
}

```

Contoh 2: Penyelesaian teks sederhana

Gunakan format penyelesaian untuk pembuatan teks sederhana:

```

# 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)

```

Sampel respon:

```

{
  "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
}
}

```

Contoh 3: Penyelesaian obrolan streaming

```

# Streaming chat request
streaming_request = {
    "messages": [
        {"role": "user", "content": "Tell me a short story about a robot"}
    ],
    "max_tokens": 200,
    "stream": True,
    "temperature": 0.7,
    "top_p": 0.95,
    "top_k": 40,
    "logprobs": True,
    "top_logprobs": 2,
    "reasoning_effort": "high", # For more detailed reasoning
    "stream_options": {"include_usage": True}
}

invoke_nova_endpoint(streaming_request)

```

Output streaming sampel:

```

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":{"content":"","reasoning_content":null},"logprobs":null,"finish_reason":"stop"}],"usage":
{"prompt_tokens":15,"completion_tokens":87,"total_tokens":102}}
Chunk: data: [DONE]

```

Contoh 4: Penyelesaian obrolan multimodal

Gunakan format multimodal untuk input gambar dan teks:

```
# 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)
```

Sampel respon:

```
{
  "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
  }
}
```

```
}
```

Langkah 7: Bersihkan sumber daya (Opsional)

Untuk menghindari biaya yang tidak perlu, hapus AWS sumber daya yang Anda buat selama tutorial ini. SageMaker endpoint dikenakan biaya saat sedang berjalan, bahkan jika Anda tidak secara aktif membuat permintaan inferensi.

Important

Menghapus sumber daya bersifat permanen dan tidak dapat dibatalkan. Pastikan Anda tidak lagi membutuhkan sumber daya ini sebelum melanjutkan.

Hapus titik akhir

```
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

Penghapusan titik akhir adalah asinkron. Anda dapat memantau status penghapusan:

```
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
```

Hapus konfigurasi titik akhir

Setelah titik akhir dihapus, hapus konfigurasi titik akhir:

```
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}")
```

Hapus model

Hapus objek SageMaker model:

```
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}")
```

Referensi API

Model Amazon Nova SageMaker menggunakan SageMaker Runtime API standar untuk inferensi. Untuk dokumentasi API yang lengkap, lihat [Menguji model yang diterapkan](#).

Pemanggilan titik akhir

Model Amazon Nova SageMaker mendukung dua metode pemanggilan:

- Pemanggilan sinkron: Gunakan [InvokeEndpoint](#) API untuk permintaan inferensi non-streaming real-time.
- Pemanggilan streaming: Gunakan [InvokeEndpointWithResponseStream](#) API untuk permintaan inferensi streaming waktu nyata.

Format permintaan

Model Amazon Nova mendukung dua format permintaan:

Format penyelesaian obrolan

Gunakan format ini untuk interaksi percakapan:

```
{
  "messages": [
    {"role": "user", "content": "string"}
  ],
  "max_tokens": integer,
  "max_completion_tokens": integer,
  "stream": boolean,
  "temperature": float,
  "top_p": float,
  "top_k": integer,
  "logprobs": boolean,
  "top_logprobs": integer,
  "reasoning_effort": "low" | "high",
  "allowed_token_ids": [integer],
  "truncate_prompt_tokens": integer,
  "stream_options": {
    "include_usage": boolean
  }
}
```

Format penyelesaian teks

Gunakan format ini untuk pembuatan teks sederhana:

```
{
  "prompt": "string",
  "max_tokens": integer,
  "stream": boolean,
  "temperature": float,
```



```
"top_p": float,  
"top_k": integer,  
"logprobs": integer,  
"allowed_token_ids": [integer],  
"truncate_prompt_tokens": integer,  
"stream_options": {  
  "include_usage": boolean  
}  
}
```

Format penyelesaian obrolan multimodal

Gunakan format ini untuk input gambar dan teks:

```
{  
  "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  
}
```

Parameter permintaan

- **messages(array)**: Untuk format penyelesaian obrolan. Array objek pesan dengan `role` dan `content` bidang. Konten dapat berupa string untuk text-only atau array untuk input multimodal.
- **prompt(string)**: Untuk format penyelesaian teks. Teks masukan untuk menghasilkan dari.
- **max_tokens(integer)**: Jumlah maksimum token yang akan dihasilkan dalam respons. Rentang: 1 atau lebih besar.
- **max_completion_tokens(integer)**: Alternatif untuk `max_tokens` untuk penyelesaian obrolan. Jumlah maksimum token penyelesaian yang akan dihasilkan.
- **temperature(float)**: Mengontrol keacakan dalam generasi. Rentang: 0,0 hingga 2,0 (0,0 = deterministik, 2,0 = keacakan maksimum).

- `top_p`(mengambang): Ambang pengambilan sampel nukleus. Rentang: 1e-10 hingga 1.0.
- `top_k`(integer): Membatasi pemilihan token ke token K teratas yang paling mungkin. Rentang: -1 atau lebih besar (-1 = tidak ada batas).
- `stream`(boolean): Apakah akan mengalirkan respons. Setel ke `true` untuk streaming, `false` untuk non-streaming.
- `logprobs`(boolean/integer): Untuk penyelesaian obrolan, gunakan boolean. Untuk penyelesaian teks, gunakan bilangan bulat untuk jumlah probabilitas log untuk kembali. Rentang: 1 hingga 20.
- `top_logprobs`(integer): Jumlah token yang paling mungkin untuk mengembalikan probabilitas log untuk (hanya penyelesaian obrolan).
- `reasoning_effort`(string): Tingkat upaya penalaran. Opsi: "rendah", "tinggi" (penyelesaian obrolan hanya untuk model khusus Nova 2 Lite).
- `allowed_token_ids`(array): Daftar token IDs yang diizinkan untuk dihasilkan. Membatasi output ke token tertentu.
- `truncate_prompt_tokens`(integer): Pangkas prompt ke banyak token ini jika melebihi batas.
- `stream_options`(objek): Opsi untuk respons streaming. Berisi `include_usage` boolean untuk menyertakan penggunaan token dalam respons streaming.

Format respons

Format respons tergantung pada metode pemanggilan dan jenis permintaan:

Respons penyelesaian obrolan (non-streaming)

Untuk permintaan penyelesaian obrolan sinkron:

```
{
  "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]
}

```

Respons penyelesaian teks (non-streaming)

Untuk permintaan penyelesaian teks sinkron:

```
{
  "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
    }
  }
}
```

Respons streaming penyelesaian obrolan

Untuk permintaan penyelesaian obrolan streaming, tanggapan dikirim sebagai Server-Sent Events (SSE):

```
data: {
  "id": "chatcmpl-123e4567-e89b-12d3-a456-426614174000",
  "object": "chat.completion.chunk",
  "created": 1677652288,
  "model": "nova-micro-custom",
  "choices": [
    {
      "index": 0,
      "delta": {
        "role": "assistant",
        "content": "Hello",
        "refusal": null,
        "reasoning": null,
        "reasoning_content": null
      },
      "logprobs": {
        "content": [
          {
            "token": "Hello",
            "logprob": -0.31725305,
            "bytes": [72, 101, 108, 108, 111],
            "top_logprobs": [
              {
                "token": "Hello",
                "logprob": -0.31725305,
                "bytes": [72, 101, 108, 108, 111]
              }
            ]
          }
        ]
      },
      "finish_reason": null,
      "stop_reason": null
    }
  ],
  "usage": null,
  "prompt_token_ids": null
}

data: {
```

```
"id": "chatcmpl-123e4567-e89b-12d3-a456-426614174000",
"object": "chat.completion.chunk",
"created": 1677652288,
"model": "nova-micro-custom",
"choices": [
  {
    "index": 0,
    "delta": {
      "content": "! I'm"
    },
    "logprobs": null,
    "finish_reason": null,
    "stop_reason": null
  }
],
"usage": null
}

data: {
  "id": "chatcmpl-123e4567-e89b-12d3-a456-426614174000",
  "object": "chat.completion.chunk",
  "created": 1677652288,
  "model": "nova-micro-custom",
  "choices": [
    {
      "index": 0,
      "delta": {},
      "finish_reason": "stop",
      "stop_reason": null
    }
  ],
  "usage": {
    "prompt_tokens": 9,
    "completion_tokens": 12,
    "total_tokens": 21,
    "prompt_tokens_details": {
      "cached_tokens": 0
    }
  }
}

data: [DONE]
```

Respons streaming penyelesaian teks

Untuk permintaan penyelesaian teks streaming:

```
data: {
  "id": "cmpl-123e4567-e89b-12d3-a456-426614174000",
  "object": "text_completion",
  "created": 1677652288,
  "model": "nova-micro-custom",
  "choices": [
    {
      "index": 0,
      "text": "Paris",
      "logprobs": {
        "tokens": ["Paris"],
        "token_logprobs": [-0.31725305],
        "top_logprobs": [
          {
            "Paris": -0.31725305,
            "London": -1.3190403
          }
        ]
      },
      "finish_reason": null,
      "stop_reason": null
    }
  ],
  "usage": null
}
```

```
data: {
  "id": "cmpl-123e4567-e89b-12d3-a456-426614174000",
  "object": "text_completion",
  "created": 1677652288,
  "model": "nova-micro-custom",
  "choices": [
    {
      "index": 0,
      "text": ", the capital",
      "logprobs": null,
      "finish_reason": null,
      "stop_reason": null
    }
  ],
}
```

```
"usage": null
}

data: {
  "id": "cmpl-123e4567-e89b-12d3-a456-426614174000",
  "object": "text_completion",
  "created": 1677652288,
  "model": "nova-micro-custom",
  "choices": [
    {
      "index": 0,
      "text": "",
      "finish_reason": "stop",
      "stop_reason": null
    }
  ],
  "usage": {
    "prompt_tokens": 5,
    "completion_tokens": 11,
    "total_tokens": 16
  }
}

data: [DONE]
```

Penjelasan bidang respons

- **id**: Pengidentifikasi unik untuk penyelesaian
- **object**: Jenis objek yang dikembalikan (“chat.completion”, “text_completion”, “chat.completion.chunk”)
- **created**: Stempel waktu Unix saat penyelesaian dibuat
- **model**: Model yang digunakan untuk penyelesaian
- **choices**: Array pilihan penyelesaian
- **usage**: Informasi penggunaan token termasuk prompt, penyelesaian, dan total token
- **logprobs**: Log informasi probabilitas untuk token (bila diminta)
- **finish_reason**: Alasan mengapa model berhenti menghasilkan (“stop”, “length”, “content_filter”)
- **delta**: Konten tambahan dalam respons streaming
- **reasoning**: Konten penalaran saat reasoning_effort digunakan

- `token_ids`: Array token IDs untuk teks yang dihasilkan

Untuk dokumentasi API selengkapnya, lihat [Referensi InvokeEndpoint](#) [InvokeEndpointWithResponseStream API](#) dan [referensi API](#).

Evaluasi Model yang Dihosting pada SageMaker Inferensi

Panduan ini menjelaskan cara mengevaluasi model Amazon Nova khusus Anda yang diterapkan pada titik akhir SageMaker inferensi menggunakan [Inspect AI](#), kerangka evaluasi sumber terbuka.

Note

Untuk panduan langsung, lihat notebook quickstart [SageMaker Inspect AI](#).

Ikhtisar

Anda dapat mengevaluasi model Amazon Nova khusus yang digunakan pada SageMaker titik akhir menggunakan tolok ukur standar dari komunitas riset AI. Pendekatan ini memungkinkan Anda untuk:

- Evaluasi model Amazon Nova yang disesuaikan (disetel dengan baik, disuling, atau disesuaikan) dalam skala besar
- Jalankan evaluasi dengan inferensi paralel di beberapa instance titik akhir
- Bandingkan kinerja model menggunakan tolok ukur seperti MMLU, TruthfulQA, dan HumanEval
- Integrasikan dengan SageMaker infrastruktur yang ada

Model yang didukung

Penyedia SageMaker inferensi bekerja dengan:

- Model Amazon Nova (Nova Micro, Nova Lite, Nova Lite 2)
- Model yang digunakan melalui server inferensi yang kompatibel dengan VLLM atau OpenAI
- Titik akhir apa pun yang mendukung format API Penyelesaian OpenAI Chat

Prasyarat

Sebelum Anda mulai, pastikan Anda memiliki:

- Sebuah Akun AWS dengan izin untuk membuat dan memanggil titik akhir SageMaker
- AWS kredensial yang dikonfigurasi melalui AWS CLI, variabel lingkungan, atau peran IAM
- Python 3.9 atau lebih tinggi

Izin IAM yang diperlukan

Pengguna atau peran IAM Anda memerlukan izin berikut:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "sagemaker:InvokeEndpoint",
        "sagemaker:DescribeEndpoint"
      ],
      "Resource": "arn:aws:sagemaker:*:*:endpoint/*"
    }
  ]
}
```

Langkah 1: Menyebarkan titik akhir SageMaker

Sebelum menjalankan evaluasi, Anda memerlukan titik akhir SageMaker inferensi yang menjalankan model Anda.

Untuk petunjuk tentang membuat titik akhir SageMaker inferensi dengan model Amazon Nova, lihat [the section called “Memulai”](#)

Setelah titik akhir Anda dalam InService status, perhatikan nama titik akhir untuk digunakan dalam perintah evaluasi.

Langkah 2: Instal dependensi evaluasi

Buat lingkungan virtual Python dan instal paket yang diperlukan.

```
# Create virtual environment
python3.12 -m venv venv
```

```
source venv/bin/activate

# Install uv for faster package installation
pip install uv

# Install Inspect AI and evaluation benchmarks
uv pip install inspect-ai inspect-evals

# Install AWS dependencies
uv pip install aioboto3 boto3 botocore openai
```

Langkah 3: Konfigurasi AWS kredensial

Pilih salah satu metode otentikasi berikut:

Opsi 1: AWS CLI (Direkomendasikan)

```
aws configure
```

Masukkan ID Kunci AWS Akses, Kunci Akses Rahasia, dan wilayah default saat diminta.

Opsi 2: Variabel lingkungan

```
export AWS_ACCESS_KEY_ID=your_access_key
export AWS_SECRET_ACCESS_KEY=your_secret_key
export AWS_DEFAULT_REGION=us-west-2
```

Opsi 3: Peran IAM

Jika berjalan di Amazon EC2 atau SageMaker notebook, peran IAM instans akan digunakan secara otomatis.

Verifikasi kredensialnya

```
import boto3

sts = boto3.client('sts')
identity = sts.get_caller_identity()
print(f"Account: {identity['Account']}")
print(f>User/Role: {identity['Arn']}")
```

Langkah 4: Instal SageMaker penyedia

SageMaker Penyedia memungkinkan Inspect AI untuk berkomunikasi dengan titik SageMaker akhir Anda. Proses instalasi penyedia disederhanakan di notebook [quickstart](#).

Langkah 5: Unduh tolok ukur evaluasi

Kloning repositori Inspect Evals untuk mengakses tolok ukur standar:

```
git clone https://github.com/UKGovernmentBEIS/inspect_evals.git
```

Repositori ini mencakup tolok ukur seperti:

- MMLU dan MMLU-Pro (pengetahuan dan penalaran)
- TruthfulQA (kebenaran)
- HumanEval (pembuatan kode)
- GSM8K (penalaran matematika)

Langkah 6: Jalankan evaluasi

Jalankan evaluasi menggunakan SageMaker endpoint Anda:

```
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
```

Parameter kunci

Parameter	Default	Deskripsi
--max-connections	10	Jumlah permintaan paralel ke titik akhir. Skala dengan jumlah instance (misalnya, 10 instance × 25 = 250).

Parameter	Default	Deskripsi
<code>--max-retries</code>	3	Coba lagi upaya untuk permintaan yang gagal. Gunakan 50-100 untuk evaluasi besar.
<code>-M region_name</code>	us-east-1	AWS wilayah tempat titik akhir Anda diterapkan.
<code>-M read_timeout</code>	600	Minta batas waktu dalam hitungan detik.
<code>-M connect_timeout</code>	60	Batas waktu koneksi dalam hitungan detik.

Rekomendasi penyetelan

Untuk titik akhir multi-instance:

```
# 10-instance endpoint example
--max-connections 250 # ~25 connections per instance
--max-retries 100     # Handle transient errors
```

Pengaturan `--max-connections` terlalu tinggi dapat membanjiri titik akhir dan menyebabkan pelambatan. Mengaturnya terlalu rendah kurang memanfaatkan kapasitas.

Langkah 7: Lihat hasil

Luncurkan penampil Inspect AI untuk menganalisis hasil evaluasi:

```
inspect view
```

Penampil menampilkan:

- Skor dan metrik keseluruhan
- Hasil per sampel dengan respons model
- Analisis kesalahan dan pola kegagalan

Mengelola titik akhir

Perbarui titik akhir

Untuk memperbarui titik akhir yang ada dengan model atau konfigurasi baru:

```
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
)
```

Hapus titik akhir

```
sagemaker.delete_endpoint(EndpointName=ENDPOINT_NAME)
```

Tolok ukur khusus orientasi

Anda dapat menambahkan tolok ukur baru ke Inspect AI menggunakan alur kerja berikut:

1. Pelajari format dataset benchmark dan metrik evaluasi
2. Tinjau implementasi serupa di `inspect_evals/`
3. Buat file tugas yang mengonversi catatan kumpulan data untuk Memeriksa sampel AI
4. Menerapkan pemecah dan pencetak gol yang tepat
5. Validasi dengan uji coba kecil

Contoh struktur tugas:

```
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()
    )
```

Pemecahan masalah

Masalah umum

Pelambatan titik akhir atau batas waktu

- Mengurangi `--max-connections`
- Meningkatkan `--max-retries`
- Periksa CloudWatch metrik titik akhir untuk masalah kapasitas

Kesalahan otentikasi

- Verifikasi AWS kredensial dikonfigurasi dengan benar
- Periksa izin IAM termasuk `sagemaker:InvokeEndpoint`

Kesalahan model

- Verifikasi titik akhir dalam status `InService`
- Periksa apakah model mendukung format OpenAI Chat Completions API

Sumber daya terkait

- [Periksa Dokumentasi AI](#)
- [Periksa Repositori Evals](#)
- [SageMaker Panduan Pengembang](#)
- [Menyebarkan Model untuk Inferensi](#)
- [Mengkonfigurasi AWS CLI](#)

Penyebaran Model Amazon Nova Forge di deteksi penyalahgunaan SageMaker Inferensi Amazon

AWS berkomitmen untuk penggunaan AI yang bertanggung jawab. [Untuk membantu mencegah potensi penyalahgunaan, saat Anda menerapkan Model Amazon Nova Forge di Inferensi Amazon SageMaker SageMaker Inferensi menerapkan mekanisme deteksi penyalahgunaan otomatis untuk](#)

mengidentifikasi potensi pelanggaran Kebijakan Penggunaan yang Dapat Diterima (AUP) dan Ketentuan Layanan, termasuk Kebijakan AI yang Bertanggung Jawab. AWS

Mekanisme deteksi penyalahgunaan kami sepenuhnya otomatis, sehingga tidak ada tinjauan manusia terhadap, atau akses ke, input pengguna atau output model.

Deteksi penyalahgunaan otomatis meliputi:

- Mengkategorikan konten — Kami menggunakan pengklasifikasi untuk mendeteksi konten berbahaya (seperti konten yang memicu kekerasan) dalam input pengguna dan keluaran model. Pengklasifikasi adalah algoritma yang memproses input dan output model, dan menetapkan jenis bahaya dan tingkat kepercayaan. Kami dapat menjalankan pengklasifikasi ini pada penggunaan Amazon Nova Forge Model. Proses klasifikasi otomatis dan tidak melibatkan tinjauan manusia terhadap input pengguna atau output model.
- Identifikasi pola — Kami menggunakan metrik pengklasifikasi untuk mengidentifikasi potensi pelanggaran dan perilaku berulang. Kami dapat mengkompilasi dan membagikan metrik pengklasifikasi anonim. SageMaker Inferensi Amazon tidak menyimpan input pengguna atau output model.
- Mendeteksi dan memblokir materi pelecehan seksual anak (CSAM) - Anda bertanggung jawab atas konten yang Anda (dan pengguna akhir Anda) unggah ke SageMaker Inferensi Amazon dan harus memastikan konten ini bebas dari gambar ilegal. Untuk membantu menghentikan penyebaran CSAM, saat menerapkan Model Amazon Nova Forge di SageMaker Amazon SageMaker Inference, Inference dapat menggunakan mekanisme deteksi penyalahgunaan otomatis (seperti teknologi pencocokan hash atau pengklasifikasi) untuk mendeteksi CSAM yang jelas. Jika SageMaker Inferensi Amazon mendeteksi CSAM yang jelas dalam input gambar Anda, Inferensi SageMaker Amazon akan memblokir permintaan dan Anda akan menerima pesan kesalahan otomatis. Amazon SageMaker Inference juga dapat mengajukan laporan ke National Center for Missing and Exploited Children (NCMEC) atau otoritas terkait. Kami menganggap serius CSAM dan akan terus memperbaiki mekanisme deteksi, pemblokiran, dan pelaporan kami. Anda mungkin diwajibkan oleh hukum yang berlaku untuk mengambil tindakan tambahan, dan Anda bertanggung jawab atas tindakan tersebut.

Setelah mekanisme deteksi penyalahgunaan otomatis kami mengidentifikasi potensi pelanggaran, kami dapat meminta informasi tentang penggunaan SageMaker Inferensi Amazon oleh Anda dan kepatuhan terhadap persyaratan layanan kami. Jika Anda tidak responsif, tidak mau, atau tidak dapat mematuhi persyaratan atau kebijakan ini, AWS dapat menangguhkan akses Anda ke Inferensi Amazon. SageMaker Anda juga dapat ditagih untuk pekerjaan inferensi yang gagal jika pengujian

otomatis kami mendeteksi respons model yang tidak konsisten dengan persyaratan dan kebijakan kami.

Hubungi AWS Support jika Anda memiliki pertanyaan tambahan. Untuk informasi lebih lanjut, lihat [Amazon SageMaker FAQs](#).

Inferensi Batuan Dasar Amazon

Setelah Anda melatih dan menguji model Amazon Nova Anda, Anda dapat menerapkannya ke Amazon Bedrock untuk inferensi skala produksi. Proses penerapan melibatkan pembuatan model Amazon Bedrock dengan CreateCustomModel API, mengekspor artefak model Anda ke sana dari bucket Amazon S3 terkelola, lalu setelah model AKTIF mengonfigurasi titik akhir dengan inferensi on-demand atau throughput yang disediakan.

Setelah membuat model kustom SageMaker, Anda dapat menggunakan CreateCustomModel API untuk menerapkannya ke Amazon Bedrock dari SageMaker escrow untuk menjalankan inferensi. Anda kemudian dapat menggunakan CreateCustomModelDeployment untuk membuat titik akhir inferensi OD atau menyiapkan inferensi throughput yang disediakan untuk model Parameter Efficient Fine Tuned (PEFT). Anda dapat menyiapkan inferensi throughput yang disediakan untuk model kustom Peringkat Penuh.

Anda juga dapat menggunakan Amazon Nova Forge SDK untuk menerapkan model Amazon Nova yang disesuaikan. Amazon Nova Forge SDK memberikan pengalaman yang efisien untuk mengekstraksi informasi yang relevan dari pekerjaan pelatihan atau pos pemeriksaan model S3 dan menerbitkannya ke Amazon Bedrock. Untuk informasi selengkapnya, lihat [Amazon Nova Forge SDK](#).

Untuk langkah-langkah mendetail untuk menyiapkan inferensi Amazon Bedrock untuk model kustom, lihat [Menerapkan model Amazon Nova yang disesuaikan ke Amazon Bedrock](#).

Bagian berikut memberikan detail lebih lanjut tentang Inferensi Sesuai Permintaan pada Model Kustom.

Menerapkan model khusus untuk inferensi sesuai permintaan

Setelah Anda berhasil membuat model kustom dengan pekerjaan penyesuaian model (fine-tuning, distilasi, atau pra-pelatihan lanjutan), Anda dapat mengatur inferensi sesuai permintaan untuk model tersebut.

Untuk menyiapkan inferensi sesuai permintaan untuk model kustom, Anda menerapkan model dengan penerapan model kustom. Setelah menerapkan model kustom, Anda menggunakan

Amazon Resource Name (ARN) deployment sebagai `modelId` parameter dalam operasi atau API `AndaInvokeModel`. Converse Anda dapat menggunakan model yang digunakan untuk inferensi sesuai permintaan dengan fitur Amazon Bedrock seperti taman bermain, Agen, dan Pangkalan Pengetahuan.

Topik

- [Model yang didukung](#)
- [Menerapkan model kustom](#)
- [Gunakan penerapan untuk inferensi sesuai permintaan](#)
- [Menghapus penerapan model kustom](#)

Model yang didukung

Anda dapat mengatur inferensi sesuai permintaan untuk model berikut:

- Kanvas Amazon Nova
- Amazon Nova Lite
- Amazon Nova Mikro
- Amazon Nova Pro

Menerapkan model kustom

Anda dapat menerapkan model kustom dengan konsol Amazon Bedrock, AWS Command Line Interface, atau AWS SDKs. Untuk informasi tentang penggunaan penerapan untuk inferensi, lihat [Menggunakan penerapan untuk inferensi sesuai permintaan](#).

Topik

- [Menerapkan model khusus \(konsol\)](#)
- [Menerapkan model kustom \(\)AWS Command Line Interface](#)
- [Menerapkan model kustom \(\)AWS SDKs](#)

Menerapkan model khusus (konsol)

Anda menerapkan model kustom dari halaman Model kustom sebagai berikut. Anda juga dapat menerapkan model dari halaman sesuai permintaan model Kustom dengan bidang yang sama. Untuk

menemukan halaman ini, di Inferensi dan Penilaian di panel navigasi, pilih Model khusus sesuai permintaan.

Untuk menerapkan model kustom

1. Masuk ke Konsol Manajemen AWS menggunakan [peran IAM dengan izin Amazon Bedrock](#), dan buka konsol Amazon Bedrock di <https://console.aws.amazon.com/nova/>
2. Dari panel navigasi kiri, pilih Model khusus di bawah model Foundation.
3. Di tab Model, pilih tombol radio untuk model yang ingin Anda terapkan.
4. Pilih Siapkan inferensi dan pilih Terapkan sesuai permintaan.
5. Dalam rincian Deployment, berikan informasi berikut:
 - Nama Deployment (wajib) - Masukkan nama unik untuk penerapan Anda.
 - Deskripsi (opsional) — Masukkan deskripsi untuk penyebaran Anda.
 - Tag (opsional) - Tambahkan tag untuk alokasi biaya dan manajemen sumber daya.
6. Pilih Buat. Saat status ditampilkan `Completed`, model kustom Anda siap untuk inferensi sesuai permintaan. Untuk informasi selengkapnya tentang penggunaan model kustom, lihat [Menggunakan penerapan untuk inferensi sesuai permintaan](#).

Menerapkan model kustom ()AWS Command Line Interface

Untuk menerapkan model kustom untuk inferensi sesuai permintaan menggunakan AWS Command Line Interface, gunakan `create-custom-model-deployment` perintah dengan Amazon Resource Name (ARN) model kustom Anda. Perintah ini menggunakan operasi [CreateCustomModelDeployment](#) API. Ini mengembalikan ARN penerapan yang dapat Anda gunakan sebagai saat membuat permintaan `modelId` inferensi. Untuk informasi tentang penggunaan penerapan untuk inferensi, lihat [Menggunakan penerapan untuk inferensi sesuai permintaan](#).

```
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

```

Menerapkan model kustom (AWS SDKs)

Untuk menerapkan model kustom untuk inferensi sesuai permintaan, gunakan operasi [CreateCustomModelDeployment](#) API dengan Amazon Resource Name (ARN) model kustom Anda. Respons mengembalikan ARN penerapan yang dapat Anda gunakan sebagai saat membuat permintaan modelId inferensi. Untuk informasi tentang penggunaan penerapan untuk inferensi, lihat [Menggunakan penerapan untuk inferensi sesuai permintaan](#).

Kode berikut menunjukkan cara menggunakan SDK for Python (Boto3) untuk menyebarkan model kustom.

```

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
```

Gunakan penerapan untuk inferensi sesuai permintaan

Setelah menerapkan model kustom untuk inferensi sesuai permintaan, Anda dapat menggunakannya untuk menghasilkan respons dengan membuat permintaan inferensi. Untuk `InvokeModel` atau `Converse` operasi, Anda menggunakan penyebaran Amazon Resource Name (ARN) sebagai `modelId`.

Untuk informasi tentang membuat permintaan inferensi, lihat topik berikut:

- [Kirim petunjuk dan hasilkan tanggapan dengan inferensi model](#)
- [Prasyarat untuk menjalankan inferensi model](#)
- [Kirim prompt dan hasilkan respons menggunakan API](#)

Menghapus penerapan model kustom

Setelah Anda selesai menggunakan model Anda untuk inferensi sesuai permintaan, Anda dapat menghapus penerapan. Setelah menghapus penerapan, Anda tidak dapat menggunakannya untuk inferensi sesuai permintaan tetapi tidak menghapus model kustom yang mendasarinya.

Anda dapat menghapus penerapan model kustom dengan konsol Amazon Bedrock, AWS Command Line Interface, atau AWS SDKs.

Important

Menghapus penerapan model kustom tidak dapat diubah. Pastikan Anda tidak lagi memerlukan penerapan sebelum melanjutkan penghapusan. Jika Anda perlu menggunakan model kustom untuk inferensi sesuai permintaan lagi, Anda harus membuat penerapan baru.

Topik

- [Menghapus penerapan model kustom \(konsol\)](#)
- [Menghapus penerapan model kustom \(\)AWS Command Line Interface](#)
- [Menghapus penerapan model kustom \(\)AWS SDKs](#)

Menghapus penerapan model kustom (konsol)

Untuk menghapus penerapan model kustom

1. Di panel navigasi, di bawah Inferensi dan Penilaian, pilih Model khusus sesuai permintaan.
2. Pilih penerapan model kustom yang ingin Anda hapus.
3. Pilih Hapus.
4. Dalam dialog konfirmasi, masukkan nama penerapan untuk mengonfirmasi penghapusan.
5. Pilih Hapus untuk mengonfirmasi.

Status penerapan akan berubah menjadi **Deleting** saat penghapusan sedang berlangsung. Setelah selesai, penyebaran akan dihapus dari daftar.

Menghapus penerapan model kustom ()AWS Command Line Interface

Untuk menghapus penerapan model kustom menggunakan AWS Command Line Interface, gunakan `delete-custom-model-deployment` perintah dengan pengenalan penerapan Anda.

```
aws bedrock delete-custom-model-deployment \
--custom-model-deployment-identifier "deployment-arn-or-name" \
--region region
```

Menghapus penerapan model kustom ()AWS SDKs

Untuk menghapus penerapan model kustom secara terprogram, gunakan operasi [DeleteCustomModelDeployment](#) API dengan Nama Sumber Daya Amazon (ARN) atau nama penerapan. Kode berikut menunjukkan cara menggunakan SDK for Python (Boto3) untuk menghapus penerapan model kustom.

```
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
```

Inferensi sesuai permintaan pada Model Kustom

Inferensi sesuai permintaan (OD) memungkinkan Anda menjalankan inferensi pada model Amazon Nova kustom Anda tanpa mempertahankan titik akhir throughput yang disediakan. Ini membantu Anda mengoptimalkan biaya dan skala secara efisien. Dengan inferensi sesuai permintaan, Anda dikenakan biaya berdasarkan penggunaan, diukur dalam token, baik masuk maupun keluar.

Persyaratan kompatibilitas

Persyaratan kompatibilitas berikut berlaku:

- Inferensi OD didukung untuk model pemahaman kustom Amazon Nova Pro, Lite dan Micro. Inferensi OD tidak didukung untuk model pembuatan konten kustom Nova.
- Inferensi OD didukung untuk model pemahaman khusus Amazon Nova yang dilatih setelah 16 Juli 2025. Model khusus yang dilatih sebelum 16 Juli 2025 tidak kompatibel dengan inferensi OD.
- Kustomisasi Amazon Bedrock: Inferensi OD didukung untuk model yang disesuaikan dengan kustomisasi Amazon Bedrock dan untuk model siswa yang disuling dari model guru dengan Amazon Bedrock.

- SageMaker Kustomisasi AI: Untuk model yang disesuaikan dengan SageMaker AI, inferensi OD hanya didukung untuk model Parameter-efficient fine-tuned (PEFT) saat model di-host di Amazon Bedrock. Ini termasuk Optimasi Preferensi Langsung ditambah PEFT. Inferensi OD tidak didukung untuk model fine-tuned peringkat penuh.

Pelatihan model dan inferensi

Saat Anda melatih model Amazon Nova Pro, Lite, atau Micro kustom baru di Amazon Bedrock atau SageMaker AI menggunakan PEFT setelah 16 Juli 2025, model tersebut akan secara otomatis kompatibel dengan opsi inferensi yang disediakan dan sesuai permintaan. Anda dapat memilih metode inferensi pilihan Anda saat menerapkan model Anda.

Untuk menggunakan inferensi OD dengan model yang dilatih setelah 16 Juli 2025, selesaikan langkah-langkah berikut:

1. [Buat pekerjaan fine-tuning baru dengan API kustomisasi Amazon Bedrock atau API kustomisasi AI. SageMaker](#)
2. [Terapkan model yang baru dilatih ke Amazon Bedrock menggunakan API. CreateCustomModel](#)
3. Terapkan untuk inferensi sesuai permintaan menggunakan API. CustomModelDeployment

Batas tarif

Batas permintaan per menit (RPM) dan token per menit (TPM) berikut berlaku untuk permintaan inferensi sesuai permintaan:

Model Dasar untuk Model Kustom	RPM untuk Penerapan Model Kustom	TPM untuk Penerapan Model Kustom
Nova 2 Lite	2.000	4.000.000

Untuk mempelajari lebih lanjut tentang kuota yang tersedia untuk Amazon Nova, lihat[Kuota untuk Amazon Nova](#).

Latensi

Anda dapat mengharapkan perbedaan end-to-end latensi (yaitu, Time To First Token (TTFT)) 20-55% antara pemanggilan model dasar dan adaptor. Nilai latensi yang tepat bervariasi menurut ukuran model dan sejalan dengan standar industri.

Keterbatasan menyesuaikan model Amazon Nova

Kustomisasi Amazon Nova tidak mendukung kemampuan berikut di SageMaker.

- SSH ke dalam instance untuk menemukan metrik

Karena kontrol keamanan di tempat, Anda tidak dapat SSH ke node master dalam instans algo-1 pelatihan untuk menemukan statistik memori atau statistik NVIDIA dan memvalidasi langkah-langkah pelatihan.

- Support untuk SDK SageMaker pelatih

SageMaker pelatih saat ini tidak tersedia untuk memulai pekerjaan pelatihan. Anda dapat memulai pekerjaan pelatihan hanya melalui API estimator hari ini.

- Kolam hangat tidak dapat diakses untuk pekerjaan SageMaker pelatihan

Karena kontrol keamanan di tempat, kolam SageMaker hangat tidak dapat digunakan untuk menyimpan instance di kolam hangat sampai waktu untuk hidup.

- Penggabungan model kustom

Menggabungkan beberapa model saat ini tidak didukung. Ini berarti bahwa membuat beberapa adaptor LoRa dan melakukan operasi multi-gabungan dengan model dasar tidak tersedia.

- Alat observabilitas yang didukung

[TensorBoard](#) adalah satu-satunya alat observabilitas yang didukung untuk melihat metrik untuk pekerjaan SageMaker pelatihan. [MLFlow](#) atau [WandB](#) saat ini tidak didukung. Untuk informasi lebih lanjut tentang menggunakan TensorBoard in SageMaker, lihat [TensorBoard di SageMaker](#).

Amazon Nova Forge

Amazon Nova Forge adalah first-of-its-kind layanan yang menawarkan organisasi cara termudah dan paling hemat biaya untuk membangun model perbatasan mereka sendiri menggunakan Nova.

Amazon Nova Forge memperkenalkan konsep model “pelatihan terbuka”, yang memberi organisasi akses ke berbagai pos pemeriksaan model awal dan kemampuan untuk memadukan data eksklusif dengan kumpulan data yang dikuratori Amazon di setiap tahap pelatihan model. Hal ini memungkinkan model untuk memaksimalkan pembelajaran dari data kepemilikan sambil meminimalkan risiko melupakan keterampilan dasar seperti penalaran.

Nova Forge menyediakan kemampuan kunci berikut:

- Akses pos pemeriksaan di semua fase pengembangan model, dan manfaatkan model Nova baru sebelum tersedia secara luas
- Padukan data milik Anda dengan data pelatihan yang dikurasi Amazon Nova
- Lakukan pembelajaran penguatan dengan fungsi penghargaan di lingkungan Anda
- Gunakan resep tombol-tekan yang dioptimalkan untuk membangun dengan Nova melalui alur kerja visual atau antarmuka baris perintah
- Gunakan Toolkit AI yang Bertanggung Jawab untuk menyelaraskan model dengan pedoman AI bertanggung jawab Amazon Nova selama proses pelatihan dan menerapkan kontrol runtime untuk memoderasi respons model selama inferensi.

Prasyarat

Topik

- [Berlangganan Nova Forge](#)
- [Prasyarat lainnya](#)

Berlangganan Nova Forge

Untuk meminta akses ke layanan Amazon Nova Forge, tambahkan tag berikut ke peran IAM konsol Anda: langganan palsu kunci dengan nilai true. Setelah Anda menambahkan tag ini ke peran Anda, silakan buka SageMaker AI Console > Pelatihan dan penyesuaian model dan klik Nova Forge. Di

halaman ini, Anda akan menemukan detail tentang layanan, informasi harga, dan kemampuan. Anda dapat meminta langganan dan kemudian mengelola langganan Anda dari halaman ini.

1. Peran harus memiliki izin untuk memanggil `apiListAttachedRolePolicy`, dan responsnya harus menyertakan salah satu `AdministratorAccess` atau `AmazonSageMakerFullAccess` kebijakan.
2. Peran masuk harus memiliki izin untuk memanggil `apiListRoleTags`, dan tag respons harus disertakan `tag.key=forge-subscription`.

Prasyarat lainnya

Juga pastikan prasyarat berikut selesai:

1. [Prasyarat umum](#)
2. Langkah tambahan untuk pengguna: Tambahkan Grup Instance Terbatas (RIG) ke SageMaker HyperPod klaster Anda (untuk menyelesaikan langkah-langkah berikut [di sini](#))

Akses dan pengaturan Nova Forge

Untuk masuk ke Nova Forge, ikuti proses 2 langkah ini:

- Langkah 1: Berlangganan Nova Forge
- Langkah 2: Siapkan HyperPod infrastruktur

Mendapatkan dokumen Nova Forge

Untuk mendapatkan dokumen Nova Forge ikuti langkah-langkah di bawah ini:

```
mkdir NovaForgeHyperpodCLI
cd NovaForgeHyperpodCLI
aws s3 cp s3://nova-forge-c7363-206080352451-us-east-1/v1/ ./ --recursive
pip install -e .
```

Langkah 1: Berlangganan Nova Forge

Ringkasan Cepat:

1. Verifikasi bahwa Anda memiliki akses administrator ke akun Amazon Web Services.
2. Arahkan ke konsol SageMaker AI dan minta akses ke Nova Forge.
3. Tunggu tim Nova mengirim email konfirmasi setelah permintaan berlangganan Anda disetujui.
4. Tandai peran eksekusi Anda dengan `forge-subscription` tag. Tag ini diperlukan untuk mengakses fitur dan pos pemeriksaan Nova Forge. Tambahkan tag berikut ke peran eksekusi Anda:
 - Kunci: `forge-subscription`
 - Nilai: `true`

Panduan terperinci

Untuk berlangganan Nova Forge dan secara efektif menggunakan layanan kustomisasi, pelanggan Amazon Web Services harus memiliki akses admin ke akun Amazon Web Services mereka atau meminta administrator mereka memberi mereka akses admin. Dokumen ini menguraikan langkah-langkah yang diperlukan untuk:

- Akses admin yang aman
- Siapkan kebijakan untuk berlangganan Nova Forge
- Akses resep kustomisasi
- Konfigurasi kustomisasi
- Pantau alur kerja
- Evaluasi pos pemeriksaan model yang disesuaikan

Opsional

Alur 1: Pengguna akun harus menghubungi admin akun untuk meminta hal berikut:

- Tambahkan `forge-subscription` tag ke akun melalui IAM (lihat Lampiran A untuk langkah-langkah).
- Tambahkan `ListRoleTags` dan `ListAttachedRolePolicies` izin melalui IAM (lihat Lampiran B untuk langkah-langkah).

Required setup for requesting subscription
To request Nova Forge subscription, your IAM role must have the "forge-subscription" tag attached and the "ListRoleTags" and "ListAttachedRolePolicies" policies added.

[Learn more ↗](#)

Nova Forge

Choose from multiple Nova model checkpoints to introduce your data at the optimal stage, mix Amazon-curated training data from each stage with your data, integrate your proprietary tools as reward functions, customize the responsible AI controls, and build your own custom frontier model.

[Request subscription](#) [Documentation ↗](#)

Subscription

Request subscription to access Nova Forge resources. Once approved, your payer account will be eligible for a 1-month free trial. **Infrastructure costs will apply during the free trial.** See Nova Forge pricing details below.

Status
☐ Not subscribed

Pilihan B

Alur: Pengguna akun harus menghubungi admin akun untuk meminta akses admin ke akun.

- Setelah akses admin diberikan, ikuti langkah-langkah di Flow 2.

Aliran 2. Akun Amazon Web Services dengan akses admin

- Tambahkan tag langganan palsu ke akun melalui IAM. Lihat Langkah-langkah dalam Lampiran A

Lampiran A. Tambahkan kebijakan berlangganan palsu ke akun Amazon Web Services

1. Buka Dasbor IAM Amazon Web Services. Klik Peran di sebelah kiri. Cari admin dan klik peran admin

Identity and Access Management (IAM)

Search IAM

Dashboard

Access management

- User groups
- Users
- Roles**
- Policies
- Identity providers
- Account settings
- Root access management
- Temporary delegation requests

Roles (181)

An IAM role is an identity you can create that has specific permissions with credentials that are valid for s

Search: admin (1 match)

Role name	Trusted
libsAdminAccess-DO-NOT-DELETE	Account:

Roles Anywhere

Authenticate your non AWS workloads and securely provide access to AWS services.

Access AWS from your non AWS workloads

Operate your non AWS workloads using the same authentication and authorization strategy that you use within AWS.

X.509 Standard

Use your own existing PKI infrastructure or [Certificate Manager Private Certificate Autl](#) to authenticate identities.

- Pilih < AssumedRoleToUse > (mis., libsAdminAccess). Klik pada tab Tag.

Identity and Access Management (IAM)

Search IAM

Dashboard

Access management

- User groups
- Users
- Roles**
- Policies
- Identity providers
- Account settings
- Root access management
- Temporary delegation requests

libsAdminAccess-DO-NOT-DELETE

Summary

Creation date
November 06, 2025, 09:29 (UTC-08:00)

Last activity
5 minutes ago


ARN
arn:aws:iam::6s-DO-NOT-DE

Maximum session
1 hour


Tags (2)

Key	Value
forge-subscription	

- Klik Kelola tab. Tambahkan tag baru. Ketik “forge-subscription” di bawah Key dan klik simpan perubahan




4. Pastikan Anda melihat langganan palsu sebagai kunci di bagian Tag




Lampiran B. Menambahkan ListRoleTags dan ListAttachedPolicies kebijakan ke akun Amazon Web Services untuk Peran Non-Admin oleh Admin

1. Buka Dasbor IAM Amazon Web Services. Klik Peran di sebelah kiri. Cari < AssumedRoleToUse > (mis., ForgeAccessRole) dan klik peran < AssumedRoleToUse > (mis., ForgeAccessRole)



2. Klik pada peran < AssumedRoleToUse > (mis., ForgeAccessRole) dan pilih Tag. Tambahkan tag baru dengan ketik “forge-subscription”



3. Di bawah Izin, tambahkan izin baru: Tambahkan Izin → Buat kebijakan sebaris → Tambahkan kebijakan berikut yang tercantum di bawah ini

```
{
  "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.

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- }

```

Langkah 2. Menyiapkan HyperPod infrastruktur

Siapkan infrastruktur yang diperlukan dengan mengikuti [petunjuk lokakarya](#) untuk mengonfigurasi lingkungan dengan fitur berkemampuan Forge.

Pengaturan moderasi konten

Jika Anda memerlukan akses ke Nova Forge, pengaturan moderasi konten yang dapat disesuaikan (CCMS) tersedia untuk model Amazon Nova Lite 1.0 dan Pro 1.0. CCMS memungkinkan penyesuaian kontrol moderasi konten untuk menyelaraskan dengan persyaratan bisnis tertentu sambil mempertahankan perlindungan AI yang bertanggung jawab yang penting. Untuk menentukan apakah model bisnis sesuai untuk CCM, hubungi Manajer AWS Akun.

Untuk informasi tambahan tentang mengonfigurasi dan menggunakan CCMS dengan model khusus, lihat bagian [Toolkit AI Bertanggung Jawab dan Moderasi Konten](#).

Lanjutan Pra-Pelatihan dan Pertengahan Pelatihan

Note

Dokumentasi rinci disediakan setelah berlangganan

Nova Forge CPT menawarkan kemampuan canggih di luar CPT standar, termasuk akses ke pos pemeriksaan menengah dan pencampuran data dengan korpus pra-pelatihan Nova. Fitur-fitur ini memungkinkan adaptasi domain yang lebih efisien dan pelestarian kemampuan umum model yang lebih baik.

Apa itu pos pemeriksaan menengah dan mengapa mereka dibutuhkan?

Pos pemeriksaan menengah adalah snapshot dari model Amazon Nova yang disimpan pada berbagai tahap pra-pelatihan, sebelum model mencapai kondisi siap produksi akhir. Selama pengembangan model, Amazon Nova menjalani beberapa fase pelatihan: pra-pelatihan awal dengan tingkat pembelajaran konstan, tingkat pembelajaran ramp-down, pelatihan ekstensi konteks, dan akhirnya pelatihan penyelarasan dan keselamatan mengikuti instruksi. Untuk CPT, pos pemeriksaan perantara seringkali lebih disukai daripada pos pemeriksaan Prod akhir karena lebih plastis dan mudah menerima adaptasi domain. Pos pemeriksaan Prod telah menjalani pelatihan penyelarasan dan keselamatan mengikuti instruksi ekstensif, yang mengoptimalkan model untuk penggunaan percakapan umum tetapi dapat membuatnya tahan terhadap mempelajari pola spesifik domain baru selama CPT. Sebaliknya, hanya pos pemeriksaan teks yang telah dilatih sebagian dan sepenuhnya yang mempertahankan karakteristik pra-pelatihan model. Mereka belum banyak diarahkan ke perilaku tertentu, menjadikannya titik awal yang lebih efisien untuk adaptasi domain. Saat melakukan CPT skala besar (>10B token), mulai dari pos pemeriksaan menengah biasanya menghasilkan

konvergensi yang lebih cepat, stabilitas pelatihan yang lebih baik, dan akuisisi pengetahuan domain yang lebih efektif. Namun, untuk CPT skala kecil (<10B token), atau ketika kemampuan mengikuti instruksi perlu dipertahankan, pos pemeriksaan Prod mungkin lebih tepat karena memungkinkan adaptasi domain sambil mempertahankan kemampuan percakapan model.

Beberapa pos pemeriksaan perantara diperlukan untuk CPT karena mereka menawarkan berbagai tingkat plastisitas model yang memengaruhi seberapa efisien model dapat menyerap pengetahuan domain baru. Pos pemeriksaan Prod terakhir telah menjalani pelatihan penyelarasan dan keselamatan mengikuti instruksi ekstensif, yang mengoptimalkannya untuk penggunaan percakapan umum tetapi membuatnya tahan terhadap mempelajari pola spesifik domain baru. Dengan kata lain, Itu telah diperkeras melalui pasca-pelatihan. Sebaliknya, pos pemeriksaan sebelumnya mempertahankan karakteristik pra-pelatihan model dan belum banyak diarahkan ke perilaku tertentu, membuatnya lebih plastis dan mudah menerima adaptasi domain.

Untuk mencapai efisiensi pelatihan terbaik, beberapa pos pemeriksaan menengah disediakan.

Pos pemeriksaan apa yang tersedia?

Nova 2.0

Ada tiga pos pemeriksaan Amazon Nova Lite 2.0.

- PRE-TRAINED - [nova-lite-2/pretraining-text-RD]: Ini adalah pos pemeriksaan setelah tingkat pembelajaran konstan dan tahap ramp-down dari pra-pelatihan Amazon Nova di mana model dilatih pada triliunan token.
- MID-TRAINED - [nova-lite-2/pretraining-text-CE]: Pos pemeriksaan ini memungkinkan volume menengah dari data tidak terstruktur diperkenalkan dengan tingkat pembelajaran yang lebih konservatif daripada pra-pelatihan, menyerap pengetahuan khusus domain sambil menghindari bencana lupa.
- POST-TRAINED - [nova-lite-2/prod]: Ini adalah pos pemeriksaan akhir model yang sepenuhnya selaras yang telah melalui semua langkah terkait dan pasca pelatihan.

Tabel berikut menguraikan kondisi yang berbeda untuk pra dan pertengahan pelatihan.

Tipe data	Melakukan	Dengan Checkpoint
Data domain mentah tidak terstruktur skala besar	Lanjutan Pra-Pelatihan	Pra-terlatih

Tipe data (dokumen, log, artikel, kode, dll.)	Melakukan	Dengan Checkpoint
Data domain mentah tidak terstruktur skala besar (dokumen, log, artikel, kode, dll.)	Pertengahan Pelatihan	Pra-terlatih
Volume data mentah tidak terstruktur yang lebih kecil. Jejak penalaran terstruktur/ data CoT	Pertengahan Pelatihan	Terlatih Tengah
Demonstrasi terstruktur (pasangan input-output berkualitas tinggi, instruksi tugas yang dikuratori, dialog multi-putaran)	Fine-Tuning Penuh	Terlatih Tengah
Demonstrasi terstruktur (pasangan input-output berkualitas tinggi, instruksi tugas yang dikuratori, dialog multi-putaran)	Parameter Fine-Tuning yang Efisien	Pasca Terlatih

Pos pemeriksaan mana yang akan digunakan?

Hanya teks yang telah dilatih sebagian dan pos pemeriksaan teks yang sepenuhnya dilatih sebelumnya biasanya berkumpul lebih cepat dan membutuhkan lebih sedikit langkah pelatihan untuk adaptasi domain. Namun, mereka tidak memiliki penyetelan instruksi dan perlu menjalani langkah-langkah pasca pelatihan untuk dapat melakukan tugas yang berguna dan mengikuti instruksi. Pos pemeriksaan GA mungkin memerlukan lebih banyak langkah untuk beradaptasi tetapi memberikan titik awal yang lebih aman untuk eksperimen skala kecil dan akan mempertahankan beberapa kemampuan pasca pelatihan TI bahkan setelah pelatihan CPT.

Secara umum, dengan kumpulan data pelatihan yang besar ($>10B$ token), mulai dari teks yang telah dilatih sebagian saja atau pos pemeriksaan teks yang sepenuhnya dilatih sebelumnya untuk pelatihan yang lebih efisien dan stabil, karena basis pengetahuan model akan dimodifikasi secara substansional. Dengan kumpulan data kecil ($<10B$ token), gunakan pos pemeriksaan GA untuk mempertahankan kemampuan mengikuti instruksi sambil beradaptasi dengan domain.

Bagaimana cara menggunakan pencampuran data untuk Nova 2.0?

Saat melakukan CPT dengan data domain baru, sangat bermanfaat untuk mencampur data baru dengan beberapa data yang digunakan sebelumnya dalam tahap pra-pelatihan model. Mencampur data lama dengan data domain baru memecahkan dua masalah:

- **Melupakan kontrol:** Mencegah bencana lupa dengan melestarikan keterampilan dan pengetahuan model yang ada. Tanpa pencampuran data, pelatihan secara eksklusif pada data domain yang sempit menyebabkan model menimpa kemampuan umum. Misalnya, model yang dilatih hanya pada dokumen hukum mungkin kehilangan kemampuannya untuk membuat kode atau melakukan matematika. Mencampur kumpulan data domain umum mempertahankan keterampilan umum ini saat memperoleh domain baru.
- **Stabilitas optimasi:** Menjaga stabilitas pelatihan dengan menambahkan representasi internal model. Selama CPT, fitur yang dipelajari model dimodifikasi dan pencampuran data memberikan gradien dari beragam sumber yang memandu adaptasi ini dengan lancar. Tanpa itu, pelatihan tentang distribusi sempit dapat menyebabkan ketidakstabilan gradien, di mana representasi model bergeser terlalu drastis, yang mengarah ke divergensi pelatihan, lonjakan kehilangan, atau runtuhnya kemampuan yang ada. Ini adalah tradeoff stabilitas-plastisitas: model harus cukup plastis untuk mempelajari pengetahuan domain baru, tetapi cukup stabil untuk tidak merusak apa yang sudah diketahui.

Kemampuan Pencampuran Data Nova CPT

Akses ke data pra-pelatihan Amazon Nova dan pos pemeriksaan adalah salah satu penawaran inti dari kustomisasi Amazon Nova CPT. Kustomisasi Amazon Nova CPT memungkinkan pencampuran data domain yang mudah dengan korpus pra-pelatihan Amazon Nova. Selanjutnya, rasio pengambilan sampel dari kategori data Amazon Nova tertentu (misalnya, kode, matematika, penalaran, dll) dapat diubah dan proporsinya dikontrol untuk melengkapi data domain. Hal ini memungkinkan penguatan kemampuan yang selaras dengan kasus penggunaan sambil mengadaptasi model ke domain tertentu.

Menemukan Rasio Pencampuran Optimal

Rasio optimal data Amazon Nova versus data domain tergantung pada domain kumpulan data, kompleksitas, ukuran, kualitas, dan pentingnya mempertahankan kemampuan umum. Rasio ini harus ditemukan melalui eksperimen. Kerangka percobaan untuk memutuskan berapa banyak data Amazon Nova yang akan dicampur adalah sebagai berikut.

Pilih subset representatif dari data domain (misalnya, token 5B) dan pertahankan konstanta ini di semua proses eksperimental.

Jalankan eksperimen CPT skala kecil dengan hanya memvariasikan jumlah data Amazon Nova yang dicampur dalam:

- Tanpa pencampuran: 100% domain → domain 5B saja (total 5B)
- Pencampuran ringan: domain 90% → Domain 5B+~ 0,56B Amazon Nova (total ~ 5,56B)
- Pencampuran sedang: domain 70% → domain 5B + ~ 2.14B Amazon Nova (total ~ 7.14B)
- Pencampuran berat: domain 50% → Domain 5B+5B Amazon Nova (total 10B)

Evaluasi setiap pos pemeriksaan di dalam domain dan tolok ukur domain umum. Juga evaluasi pos pemeriksaan awal (pos pemeriksaan Amazon Nova sebelum pelatihan apa pun).

- Apakah kinerja domain pelanggan tetap kira-kira konstan di seluruh proses? Biasanya harus, karena setiap run melihat jumlah token domain yang sama. Jika kinerja domain meningkat dengan lebih banyak pencampuran, data Amazon Nova memberikan regularisasi yang berguna.
- Apakah skor benchmark umum meningkat saat pencampuran meningkat?
 - Perilaku yang diharapkan adalah bahwa kemampuan umum harus meningkat secara monoton karena lebih banyak data Amazon Nova ditambahkan.
 - Ukur beberapa tolok ukur umum: MMLU (pengetahuan umum), HumanEval (pengkodean), GSM8 K (matematika), atau tolok ukur tertentu yang menarik.
- Pilih rasio pencampuran yang mempertahankan kinerja domain sambil memberikan kemampuan umum yang dapat diterima untuk kasus penggunaan. Faktor biaya tambahan pelatihan dengan lebih banyak pencampuran data.

Setelah rasio pencampuran optimal diidentifikasi, jalankan CPT skala penuh menggunakan kumpulan data domain lengkap dengan rasio pencampuran yang dipilih.

Membedah Kategori Pencampuran Data

Di bawah ini kami membedah setiap kategori yang tersedia dalam Pencampuran Data, agar Anda dapat membuat keputusan terbaik tentang kategori data apa yang paling masuk akal untuk diwakili dalam campuran data Anda secara keseluruhan.

Cara Mengaktifkan Pencampuran Data

Tambahkan `data_mixing` bagian ke resep Anda dengan distribusi persentase yang sesuai di seluruh kategori kumpulan data. `nova_data` Persentase harus berjumlah 100.

Konfigurasi Nova 2.0 dengan pencampuran data

```
# 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

```

Apa arti kategori ini

Catatan: Nova 2.0 menyertakan kategori khusus penalaran tambahan (misalnya,, reasoning-codereasoning-math,reasoning-instruction-following) yang tidak tersedia di Nova 1.0.

Ringkasan Kategori dan Label Info:

Nama Kategori	Detail info
agents	Data pelatihan berfokus pada pengambilan keputusan otonom, penyelesaian tugas, dan perilaku berorientasi pada tujuan dalam sistem AI
baseline	Data bahasa dasar berfokus pada pemahaman umum, komunikasi dasar, dan kemampuan linguistik inti
chat	Pertukaran percakapan yang menunjukkan aliran dialog alami, pemeliharaan konteks, dan interaksi sosial yang sesuai
code	Pemrograman kode sumber, dokumentasi, dan diskusi teknis dari berbagai bahasa dan platform pemrograman.
factuality	Bahan referensi dan informasi terverifikasi yang berfokus pada akurasi, validasi sumber, dan penilaian kebenaran
identity	Kerangka kepribadian dan pola perilaku berfokus pada sifat karakter, nilai, dan gaya interaksi yang konsisten
long-context	Teks yang diperluas dan narasi kompleks difokuskan pada pemeliharaan koherensi dan relevansi di seluruh pertukaran yang panjang
math	Konten matematika termasuk buku teks, masalah, solusi, dan diskusi matematika.

Nama Kategori	Detail info
rai	Kasus dan skenario yang menekankan prinsip AI etis, pertimbangan keselamatan, dan penerapan teknologi yang bertanggung jawab
instruction-following	Contoh pelaksanaan tugas yang tepat berdasarkan berbagai tingkat permintaan dan arahan pengguna
stem	Konten teknis yang mencakup sains, teknologi, teknik, dan matematika, termasuk pemecahan masalah dan konsep teoritis
planning	Urutan yang menunjukkan pemikiran strategis, pemecahan step-by-step tugas, dan alokasi sumber daya yang efisien
reasoning-chat	Skenario dialog analitis berfokus pada diskusi logis dan alur percakapan terstruktur
reasoning-code	Tantangan pemrograman dan masalah algoritmik difokuskan pada pengembangan solusi sistematis
reasoning-factuality	Skenario evaluasi informasi berfokus pada penilaian kritis dan proses verifikasi
reasoning-instruction-following	Analisis tugas kompleks berfokus pada interpretasi sistematis dan eksekusi metodelis
reasoning-math	Skenario pemecahan masalah matematika berfokus pada perkembangan logis dan strategi solusi
reasoning-planning	Skenario pengambilan keputusan strategis berfokus pada pendekatan sistematis untuk pencapaian tujuan
reasoning-rag	Skenario pengambilan informasi dan sintesis berfokus pada pemahaman kontekstual dan aplikasi yang relevan
reasoning-rai	Skenario pengambilan keputusan etis berfokus pada evaluasi sistematis keamanan dan keadilan AI

Nama Kategori	Detail info
reasoning-stem	Skenario pemecahan masalah ilmiah yang berfokus pada analisis metodis dan pengembangan solusi
rag	Contoh menggabungkan pengetahuan eksternal yang diambil secara efektif dengan tanggapan yang dihasilkan untuk memberikan informasi kontekstual yang akurat
translation	Pasangan konten multi-bahasa menunjukkan terjemahan yang akurat sambil mempertahankan konteks, nada, dan nuansa budaya

Panduan Parameter

- `dataset_catalog`: Satu-satunya nilai adalah `cpt_text_lite` untuk saat ini, sampai kita mengaktifkan pelatihan multimodal.
- `nova_data`: Persentase masing-masing kategori data Nova saat dicampur. Mereka harus menambahkan hingga 1.0.
- `customer_data`: persentase data pelanggan yang dicampur ke dalam data Nova.

Jumlah total token yang digunakan dalam pelatihan dapat dihitung dari $\text{max\_length} * \text{global\_batch\_size} * \text{max\_steps}$

Batasan

CPT saat ini hanya mendukung data teks dan tidak mendukung kumpulan data multi-modal pelanggan.

Fine-Tuning yang Diawasi

Pengantar

Penyetelan halus yang diawasi menggunakan kumpulan data dengan pasangan input-output untuk tugas yang diinginkan. Dengan kata lain, Anda memberikan contoh petunjuk (pertanyaan, instruksi, dll.) Bersama dengan tanggapan yang benar atau yang diinginkan dan melanjutkan pelatihan model tentang ini. Bobot model disesuaikan untuk meminimalkan kerugian yang diawasi, biasanya lintas entropi antara prediksi dan token respons target.

Kapan menggunakan SFT?

SFT adalah yang terbaik ketika Anda memiliki tugas yang terdefinisi dengan baik dengan output yang diinginkan yang jelas. Jika Anda dapat secara eksplisit mengatakan “Diberikan input X, correct/desired outputnya adalah Y” dan Anda dapat mengumpulkan contoh pemetaan XY tersebut, maka fine-tuning yang diawasi adalah pilihan yang bagus. Beberapa skenario di mana SFT unggul meliputi:

- Tugas klasifikasi terstruktur atau kompleks: misalnya mengklasifikasikan dokumen internal atau kontrak ke dalam banyak kategori kustom. Dengan SFT, model dapat mempelajari kategori-kategori spesifik ini jauh lebih baik daripada mendorong saja.
- Tugas penjawab pertanyaan atau transformasi dengan jawaban yang diketahui: misalnya menyempurnakan model untuk menjawab pertanyaan dari basis pengetahuan perusahaan, atau untuk mengonversi data antar format, di mana setiap input memiliki respons yang benar.
- Pemformatan dan konsistensi gaya: Jika Anda membutuhkan model untuk selalu merespons dalam format atau nada tertentu, Anda dapat menyempurnakan contoh format/nada yang benar. Misalnya, pelatihan pada pasangan respons cepat yang menunjukkan suara atau gaya merek tertentu dapat mengajarkan model dengan gaya itu dalam outputnya. Perilaku mengikuti instruksi sering kali awalnya diajarkan melalui SFT pada contoh perilaku asisten yang baik yang dikuratori.

SFT adalah cara paling langsung untuk mengajarkan LLM keterampilan atau perilaku baru ketika Anda dapat menentukan seperti apa perilaku yang benar. Ini memanfaatkan pemahaman bahasa model yang ada dan memfokuskannya pada tugas Anda. Jangan gunakan SFT ketika kesenjangan adalah pengetahuan daripada perilaku; itu tidak akan membuat model mempelajari fakta baru, jargon, atau peristiwa baru-baru ini. Dalam kasus tersebut, lebih suka pra-pelatihan lanjutan pada korpora dalam domain besar atau generasi tambahan pengambilan untuk membawa pengetahuan eksternal pada kesimpulan. Ketika Anda dapat mengukur kualitas tetapi tidak dapat memberi label satu jawaban yang benar, penyempurnaan penguatan dengan imbalan yang dapat diverifikasi atau LLM-as-judge mungkin lebih disukai daripada SFT.

Bergantung pada kompleksitas tugas dan kinerja model Nova tanpa penyetelan, rencanakan ribuan hingga puluhan ribu demonstrasi per tugas, dengan kualitas data, konsistensi, dan keragaman lebih penting daripada volume mentah.

Kapan menggunakan parameter efisien dan kapan peringkat penuh SFT?

Resep kustomisasi Nova memungkinkan Anda melakukan parameter yang efisien, khususnya LoRa, atau SFT peringkat penuh. Jika Anda menginginkan pembaruan model yang mudah dan hemat

biaya, atau memiliki sedikit data, pilih metode hemat parameter sehingga Anda melatih adaptor kecil sambil membiarkan sebagian besar tulang punggung tidak tersentuh (SFT peringkat penuh memperbarui semua parameter model).

Pencampuran Data untuk SFT

Pencampuran data memungkinkan Anda untuk menggabungkan kumpulan data pelatihan khusus Anda dengan data pelatihan milik Nova. Fitur ini tersedia untuk model Nova 1.0 dan Nova 2.0.

Nova Proprietary Data Type: Nova mendukung tipe data SFT teks dan multimodal. Ini diatur ke dalam beberapa kategori data yang masing-masing berisi campuran tugas yang relevan untuk kategori yang sesuai.

Nova Proprietary Data Kategori: Kumpulan data teks mencakup beberapa kategori termasuk: pengambilan keputusan otonom, penyelesaian tugas, kumpulan data berorientasi tujuan (agen), baik set data eksekusi tugas yang tepat penalaran maupun non-penalaran (, mengikuti instruksi)reasoning-instruction-following, urutan yang menunjukkan pemikiran strategis dan pemecahan step-by-step tugas (perencanaan), AI yang bertanggung jawab (rai), konteks panjang, faktualitas, matematika, batang dan banyak lagi. Demikian pula, kumpulan data multimodal mencakup video, tangkapan layar, bagan, dan banyak lagi.

Fitur pencampuran data memungkinkan Anda untuk memadukan sampel pelatihan fine-tuning Anda sendiri dengan sampel dari kumpulan data Nova yang digunakan untuk menyempurnakan Nova. Ini dapat mencegah overfitting pada pelatihan khusus Anda dan “bencana melupakan” kemampuan Nova, atau membantu Anda membangun kemampuan saat berlatih dari pos pemeriksaan baru yang telah dilatih sebelumnya.

Untuk mencampur data Nova, Anda hanya perlu menambahkan blok `data_mixing` ke file YAMM resep Anda, di bawah bagian `training_config`. Blok pencampuran data teks dan multi-modal memiliki konten yang berbeda. Silakan merujuk ke resep yang sesuai.

Model yang Didukung

- Nova 2.0 Lite

Modalitas yang Didukung

- Teks
- Multimodal

Contoh Konfigurasi YAMB

Contoh Konfigurasi Nova 2.0

```
run:
  name: my-lora-sft-run
  model_type: amazon.nova-2-lite-v1:0:256k
  model_name_or_path: nova-lite-2/prod
  data_s3_path: s3://my-bucket-name/train.jsonl
  replicas: 4
  output_s3_path: s3://my-bucket-name/outputs/
  mlflow_tracking_uri: ""
  mlflow_experiment_name: "my-lora-sft-experiment"
  mlflow_run_name: "my-lora-sft-run"

training_config:
  max_steps: 100
  save_steps: 10
  save_top_k: 5
  max_length: 32768
  global_batch_size: 32
  reasoning_enabled: true
  lr_scheduler:
    warmup_steps: 15
    min_lr: 1e-6
  optim_config:
    lr: 1e-5
    weight_decay: 0.0
    adam_beta1: 0.9
    adam_beta2: 0.95
  peft:
    peft_scheme: "lora"
    lora_tuning:
      alpha: 64
      lora_plus_lr_ratio: 64.0
```

Pencampuran Data Teks Nova 2.0

```
data_mixing:
  dataset_catalog: sft_1p5_text_chat
```

```
sources:
  customer_data:
    percent: 50
  nova_data:
    agents: 1
    baseline: 10
    chat: 0.5
    code: 10
    factuality: 0.1
    identity: 1
    long-context: 1
    math: 2
    rai: 1
    instruction-following: 13
    stem: 0.5
    planning: 10
    reasoning-chat: 0.5
    reasoning-code: 0.5
    reasoning-factuality: 0.5
    reasoning-instruction-following: 45
    reasoning-math: 0.5
    reasoning-planning: 0.5
    reasoning-rag: 0.4
    reasoning-rai: 0.5
    reasoning-stem: 0.4
    rag: 1
    translation: 0.1
```

Pencampuran Data Multimodal Nova 2.0

```
data_mixing:
  dataset_catalog: sft_1p5_mm_chat
  sources:
    customer_data:
      percent: 50
    nova_data:
      charts: 1
      chat: 38
      code: 20
      docs: 3
      general: 2
      grounding: 1
```

```
rag: 4
screenshot: 4
text: 8
translation: 4
video: 15
```

Pos Pemeriksaan Model

Pos Pemeriksaan Nova 2.0

- **PRE-TRAINED** [nova-lite-2/pretraining-text-RD]: Pos pemeriksaan setelah tingkat pembelajaran konstan dan tahap ramp-down di mana model dilatih pada triliunan token. [Hasil Tahap 2]
- **nova-lite-2/pretraining-text-CEMID-TRAINED** []: Memungkinkan pelanggan dengan volume menengah data tidak terstruktur untuk memperkenalkan data mereka dengan tingkat pembelajaran yang lebih konservatif daripada pra-pelatihan, menyerap pengetahuan khusus domain sambil menghindari bencana lupa. [Hasil Tahap 3]
- **FINAL** [nova-lite-2/prod]: Pos pemeriksaan akhir yang sepenuhnya selaras yang telah melalui semua langkah pra-pelatihan dan pasca pelatihan. [Hasil Tahap 4]

Tahapan Pelatihan:

- Tahap 1: PT Ckpt, pra-pelatihan awal dengan tingkat pembelajaran konstan
- Tahap 2: PT Ckpt, tingkat pembelajaran ramp-down
- Tahap 3: PT Ckpt, pelatihan penyuluhan konteks
- Tahap 4: pelatihan penyelarasan dan keselamatan mengikuti instruksi

Pendekatan Pelatihan

Panduan Pemilihan Pendekatan Pelatihan

Tipe data	Volume Data	Melakukan	Dengan Checkpoint
Data domain mentah tidak terstruktur skala besar (dokumen, log, artikel, kode, dll.)	1T+Token	Lanjutan Pra-Pelatihan	Akhir Tingkat Pembelajaran Konstan (CLR)

Tipe data	Volume Data	Melakukan	Dengan Checkpoint
Data domain mentah tidak terstruktur skala besar	100B+Token	Pertengahan Pelatihan	Akhir dari CLR
Volume data mentah tidak terstruktur yang lebih kecil; Jejak penalaran terstruktur/ data CoT	1B+Token	Pertengahan Pelatihan	Model dasar Nova
Demonstrasi terstruktur (pasangan input-output berkualitas tinggi, instruksi tugas yang dikuratori, dialog multi-putaran)	1K+ Contoh	Fine-Tuning yang Diawasi (SFT)	Model dasar Nova

Prasyarat sebelum Anda mulai

- Kami berasumsi bahwa Anda telah menyiapkan klaster SMHP dengan grup instans terbatas (RIG) yang memiliki kapasitas aktif. [Jika tidak, silakan lihat di sini untuk menyelesaikan pengaturan SMHP Cluster dan RIG Anda \[Docs Link, Workshop Link\]](#)
- Anda akan memerlukan instans EC2 p5.48xlarge untuk menjalankan resep ini. Contoh jumlah minimum yang diperlukan untuk menjalankan resep ini secara efisien adalah sebagai berikut:
 - Nova Lite 2.0 - 4 p5.48xbesar
- [Instal SageMaker HyperPod CLI Forge Specific menggunakan instruksi yang disediakan di sini](#)
- Konfirmasikan bahwa Anda dapat terhubung ke cluster Anda menggunakan `hyperpod get-clusters`
 - Perhatikan bahwa perintah ini akan mencantumkan semua cluster SMHP di akun Anda
- Konfirmasikan bahwa pelatihan Anda, dan data validasi opsional, tersedia di bucket S3 yang dapat diakses oleh peran eksekusi klaster SMHP Anda. Untuk persiapan data, lihat bagian selanjutnya.
- Telah penyiapan selesai. Jika Anda belum menyelesaikan pengaturan, silakan ikuti [panduan](#) di bawah ini.

- Verifikasi: Setelah menyelesaikan penyiapan, konfirmasi bahwa Anda berhasil menjalankan perintah di bawah ini

```
aws sagemaker describe-cluster --cluster-name <cluster-name> --region <region>

hyperpod connect-cluster --cluster-name cluster-name
```

Pendekatan Sistematis untuk Mencapai SFT yang Sukses

- Persiapan Data: Ikuti pedoman yang ditetapkan untuk membuat, membersihkan, atau memformat ulang kumpulan data ke dalam struktur yang diperlukan. Pastikan bahwa input, output, dan informasi tambahan (seperti jejak penalaran atau metadata) diselaraskan dan diformat dengan benar.
- Konfigurasi Pelatihan: Tentukan bagaimana model akan dilatih. Saat menggunakan Amazon SageMaker HyperPod, konfigurasi ini ditulis dalam file resep YAMB yang mencakup:
 - Jalur sumber data (kumpulan data pelatihan dan validasi)
 - Hiperparameter kunci (jumlah langkah pelatihan, tingkat pembelajaran, ukuran batch)
 - Komponen opsional (parameter pelatihan terdistribusi, dll)
 - Pengaturan Pencampuran Data (mendefinisikan proporsi kategori data pelanggan dan Nova)
- Optimalkan Parameter Hiper SFT: Nilai parameter resep SFT yang kami rekomendasikan adalah titik awal yang bagus dan pilihan yang kuat. Jika Anda ingin mengoptimalkannya lebih lanjut untuk kasus penggunaan Anda, lakukan beberapa SFT berjalan dengan kombinasi parameter yang berbeda dan pilih yang terbaik. Anda dapat memilih kombinasi parameter mengikuti metode Hyper-Parameter Optimization pilihan Anda. Pendekatan sederhana adalah memvariasikan nilai satu parameter (default*0.5, default, default*2) sambil mempertahankan nilai default lainnya untuk parameter lain, ulangi ini untuk setiap parameter yang ingin Anda optimalkan, dan ulangi jika diperlukan. Parameter yang paling relevan untuk LoRa adalah tingkat pembelajaran, alfa (parameter penskalaan), jumlah zaman untuk melatih dan langkah pemanasan; untuk peringkat penuh itu terutama tingkat pembelajaran, jumlah zaman, dan langkah pemanasan.

Pengurutan Eksperimen dan Pencampuran Data

- Jika Anda hanya memiliki data SFT (train/dev/test) untuk serangkaian tugas dan hanya peduli tentang kinerja pengujian pada tugas-tugas ini
 - Lakukan SFT tanpa mencampur di pos pemeriksaan [FINAL] Nova. Gunakan parameter hiper SFT default dan optimalkan secara opsional untuk kasus penggunaan Anda. Metrik validasi monitor and/or mengevaluasi pos pemeriksaan menengah untuk kumpulan data yang lebih besar.
- Jika Anda hanya memiliki data SFT (train/dev/test) untuk serangkaian tugas dan peduli dengan kinerja pengujian pada tugas-tugas ini dan tolok ukur umum dalam domain yang diminati
 - Mulailah dengan melakukan SFT dengan pencampuran data Nova di pos pemeriksaan pra-pelatihan (pos pemeriksaan PRE-TRAINED atau MID-TRAINED, bukan FINAL). Menggunakan pos pemeriksaan perantara memungkinkan model untuk mengintegrasikan data kustom Anda dengan lebih baik dengan data milik Nova sambil mempertahankan kemampuan umum yang kuat.
 - Jalankan pelatihan SFT yang lebih pendek dengan jumlah data Nova yang bervariasi dalam campuran (misalnya, 10%, 25%, 50%, 75%) dan pilihan kategori data Nova yang melengkapi kasus penggunaan Anda (misalnya, pilih instruksi berikut kategori jika Anda peduli dengan instruksi umum mengikuti kemampuan). Pantau metrik validasi dan evaluasi apakah pencampuran membantu kinerja pada tolok ukur umum. Pilih campuran pelatihan dan pos pemeriksaan yang mengarah ke kombinasi kinerja terbaik pada tugas dan kinerja umum Anda. Bergantung pada kasus penggunaan, tugas dan kinerja umum dapat ditingkatkan lebih lanjut menggunakan penyyetelan halus penguatan (RFT).

Siapkan Dataset untuk SFT

Nova 2.0: Gunakan format Converse API <https://docs.aws.amazon.com/bedrock/latest/userguide/conversation-inference-call.html>. Format data Nova 2.0 dapat berisi bidang penalaran tambahan: https://docs.aws.amazon.com/bedrock/latest/APIReference/APIReasoningContentBlock_runtime_.html

Konten penalaran menangkap langkah-langkah pemikiran menengah model sebelum menghasilkan jawaban akhir. Pada assistant gilirannya, gunakan `reasoningContent` bidang untuk memasukkan jejak penalaran. Gunakan teks biasa untuk penalaran konten, hindari tag markup seperti `<thinking>` dan `</thinking>` kecuali secara khusus diperlukan oleh tugas Anda, dan pastikan konten penalaran jelas dan relevan dengan proses pemecahan masalah.

Metode Evaluasi

Prasyarat

- Checkpoint S3 URI dari `manifest.json` file pekerjaan pelatihan Anda (untuk model terlatih)
- Dataset evaluasi diunggah ke S3 dalam format yang benar
- Output jalur S3 untuk hasil evaluasi

Tolok ukur di luar kotak: Gunakan tolok ukur di luar kotak untuk memvalidasi kinerja pada tugas umum. Untuk lebih jelasnya, periksa di sini: <https://docs.aws.amazon.com/sagemaker/latest/dg/nova-hp-evaluate.html>

Bawa Data Anda Sendiri

Anda juga dapat menyediakan data kustom Anda dengan memformatnya dalam format di bawah ini dan kemudian menggunakan wadah yang disebutkan di bawah ini untuk mendapatkan hasil inferensi bersama dengan probabilitas log untuk kalibrasi jika diperlukan.

Buat jsonl per tugas dengan struktur berikut:

```
{
  "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"
}
```

Output yang dihasilkan selama fase inferensi pekerjaan evaluasi akan memiliki struktur sebagai berikut:

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

Deskripsi bidang:

- **prompt:** Input diformat dikirim ke model
- **inference:** Respons yang dihasilkan model
- **gold:** Diharapkan jawaban yang benar dari dataset input, bidang respons dari input
- **metadata:** Metadata opsional dilewatkan dari input

Siapkan Evaluasi Config

Perintah untuk meluncurkan pekerjaan evaluasi. Gunakan "--override-parameters" untuk memodifikasi entri apa pun dari resep.

```
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"
  }'
```

Praktik Terbaik

- Prioritaskan kualitas data daripada volume: Data pelatihan berkualitas tinggi, beragam, dan representatif lebih berharga daripada data berkualitas rendah dalam jumlah besar.
- Sertakan reasoning-instruction-following kategori: Saat menggunakan pencampuran data, sertakan kategori reasoning-instruction-following "" untuk mempertahankan kinerja generik yang kuat di seluruh tugas.

- Gunakan tingkat pembelajaran default: Mulailah dengan tingkat pembelajaran default (1e-5 untuk LoRa, 5e-6 untuk SFT peringkat penuh) dan sesuaikan hanya jika diperlukan berdasarkan metrik validasi.
- Pencampuran data Balance Nova: Campurkan data Nova maksimum 50% untuk keseimbangan kinerja latensi yang optimal. Persentase yang lebih tinggi dapat meningkatkan kemampuan umum tetapi dapat meningkatkan waktu pelatihan.
- Monitor metrik validasi: Evaluasi pos pemeriksaan perantara secara teratur selama pelatihan untuk mendeteksi overfitting atau penurunan kinerja lebih awal.
- Uji pada kumpulan data representatif: Pastikan kumpulan data evaluasi Anda secara akurat mewakili kasus penggunaan produksi Anda untuk penilaian kinerja yang bermakna.

Siapkan Training Job Config

Parameter Hiper

Set lengkap parameter hiper selain pencampuran data:

```
## 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)

```

Parameter yang paling relevan untuk LoRa adalah tingkat pembelajaran, alfa (parameter penskalaan), jumlah zaman untuk melatih dan langkah pemanasan; untuk peringkat penuh itu terutama tingkat pembelajaran, jumlah zaman, dan langkah pemanasan. Resep sudah diisi sebelumnya dengan default yang direkomendasikan.

Mengatur Blok Pencampuran Data

Tambahkan bagian `data_mixing` ke resep Anda dengan distribusi persentase yang sesuai di seluruh kategori kumpulan data.

Di bawah ini kami menjelaskan setiap kategori data Nova yang tersedia.

Konfigurasi Nova 2.0 dengan pencampuran data

```
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
```


Apa arti kategori ini?

Kategori Data Teks Nova 2.0

Nama Kategori	Detail info
pelaku	Data pelatihan berfokus pada pengambilan keputusan otonom, penyelesaian tugas, dan perilaku berorientasi pada tujuan dalam sistem AI
garis dasar	Data bahasa dasar berfokus pada pemahaman umum, komunikasi dasar, dan kemampuan linguistik inti
ngobrol	Pertukaran percakapan yang menunjukkan aliran dialog alami, pemeliharaan konteks, dan interaksi sosial yang sesuai
code	Pemrograman kode sumber, dokumentasi, dan diskusi teknis dari berbagai bahasa dan platform pemrograman.
faktualitas	Bahan referensi dan informasi terverifikasi yang berfokus pada akurasi, validasi sumber, dan penilaian kebenaran
identitas	Kerangka kepribadian dan pola perilaku berfokus pada sifat karakter, nilai, dan gaya interaksi yang konsisten
konteks panjang	Teks yang diperluas dan narasi kompleks difokuskan pada pemeliharaan koherensi dan relevansi di seluruh pertukaran yang panjang
matematika	Konten matematika termasuk buku teks, masalah, solusi, dan diskusi matematika.

Nama Kategori	Detail info
rai	Kasus dan skenario yang menekankan prinsip AI etis, pertimbangan keselamatan, dan penerapan teknologi yang bertanggung jawab
instruksi-mengikuti	Contoh pelaksanaan tugas yang tepat berdasarkan berbagai tingkat permintaan dan arahan pengguna
asal	Konten teknis yang mencakup sains, teknologi, teknik, dan matematika, termasuk pemecahan masalah dan konsep teoritis
perencanaan	Urutan yang menunjukkan pemikiran strategis, pemecahan step-by-step tugas, dan alokasi sumber daya yang efisien
penalaran-obrolan	Skenario dialog analitis berfokus pada diskusi logis dan alur percakapan terstruktur
kode penalaran	Tantangan pemrograman dan masalah algoritmik difokuskan pada pengembangan solusi sistematis
penalaran-faktualitas	Skenario evaluasi informasi berfokus pada penilaian kritis dan proses verifikasi
reasoning-instruction-following	Analisis tugas kompleks berfokus pada interpretasi sistematis dan eksekusi metodis
penalaran-matematika	Skenario pemecahan masalah matematika berfokus pada perkembangan logis dan strategi solusi
penalaran-perencanaan	Skenario pengambilan keputusan strategis berfokus pada pendekatan sistematis untuk pencapaian tujuan

Nama Kategori	Detail info
penalaran-kain	Skenario pengambilan informasi dan sintesis berfokus pada pemahaman kontekstual dan aplikasi yang relevan
penalaran-rai	Skenario pengambilan keputusan etis berfokus pada evaluasi sistematis keamanan dan keadilan AI
batang penalaran	Skenario pemecahan masalah ilmiah yang berfokus pada analisis metodis dan pengembangan solusi
lap	Contoh menggabungkan pengetahuan eksternal yang diambil secara efektif dengan tanggapan yang dihasilkan untuk memberikan informasi kontekstual yang akurat
terjemahan	Pasangan konten multi-bahasa menunjukkan terjemahan yang akurat sambil mempertahankan konteks, nada, dan nuansa budaya

Pencampuran Data Multimodal (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
```

Catatan: Nova 2.0 menyertakan dukungan kategori data video yang tidak tersedia di Nova 1.0.

Apa arti kategori ini?

Kategori Data Multimodal Nova 2.0

Nama Kategori	Detail info
grafik	Representasi visual dan deskripsi grafik, diagram lingkaran, diagram batang, plot garis, dan visualisasi statistik lainnya untuk membantu model memahami dan mengkomunikasikan informasi kuantitatif secara efektif
ngobrol	Data percakapan dipasangkan dengan elemen visual yang berfokus pada pemahaman dialog kontekstual dan interaksi berbasis gambar
code	Antarmuka pemrograman dan lingkungan pengembangan yang berfokus pada interpretasi kode visual, tangkapan layar IDE, dan diagram teknis
docs	Data dokumen-sentris yang menggabungkan teks, gambar, tata letak, dan pemformatan untuk melatih model dalam memahami dan memproses berbagai jenis dan struktur dokumen untuk membantu konsep seperti pengenalan konten PDF
umum	Beragam konten visual-tekstual berfokus pada pemahaman luas gambar, grafik, dan teks deskriptif yang menyertainya

Nama Kategori	Detail info
mendasari	Bahan referensi visual dan citra berlabel berfokus pada menghubungkan konsep bahasa dengan representasi visual dunia nyata
lap	Contoh pengambilan multimodal yang menunjukkan cara menggabungkan dan mereferensikan pengetahuan eksternal visual dan tekstual secara efektif untuk menghasilkan respons kontekstual yang akurat
tangkapan layar	Antarmuka aplikasi menangkap dan gambar tampilan digital yang berfokus pada pemahaman antarmuka perangkat lunak dan interaksi digital
text	Kumpulan data teks kontekstual yang seimbang dibuat dari kategori dataset SFT Nova khusus teks untuk memberikan kemampuan generalis
terjemahan	Konten visual lintas bahasa berfokus pada interpretasi multibahasa teks dalam gambar dan elemen visual budaya
video	Konten visual berbasis gerakan berfokus pada pemahaman temporal dan pemahaman visual-naratif berurutan

Cara Meluncurkan Pekerjaan

Anda juga dapat merujuk ke README, jika Anda hanya perlu mendapatkan detail penting untuk memulai lari SFT pertama.

Informasi Kontainer:

Informasi Kontainer dan Perintah Peluncuran

Model	Teknik	Subkategori	URI citra	Perintah Peluncur Hyperpod
Nova 2.0	Penyetelan halus	Teks SFT	708977205387.dkr.ecr.us-east-1.amazonaws.com/:SM-HP-SFT-V2-Terbaru nova-fine-tune-repo	hyperpod start-job\ -n kubeflow\ --resep baik-baik saja- -:SM-HP-SFT-V2-terbaru"} 'tuning/nova/nova_2_0/nova_lite/SFT/nova_lite_2_0_p5_gpu_sft \ --override-parameters '{ "instance_type": "ml.p5.48xlarge", "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/novafine-tune-repo
Nova 2.0	Penyetelan halus	Teks SFT +Datamixing	708977205387.dkr.ecr.us-east-1.amazonaws.com/:SM-HP-SFT-V2-Datamixing-terbaru nova-fine-tune-repo	hyperpod start-job\ -n kubeflow \ --resep baik-baik saja- -:SM-HP-SFT-V2-Datamixing-terbaru"} 'tuning/nova/forgeno/nova_2_0/nova_lite/SFT/

Model	Teknik	Subkategori	URI citra	Perintah Peluncur Hyperpod
				<pre>nova_lite_2_0_p5_gpu_sft_text_with_datamix \ --override-parameters '{ "instance_type": "ml.p5.48xlarge", "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/novafine-tune-repo"</pre>

Model	Teknik	Subkategori	URI citra	Perintah Peluncur Hyperpod
Nova 2.0	Penyetelan halus	SFT MM	708977205387.dkr.ecr.us-east-1.amazonaws.com /:SM-HP-SFT-V2-Terbaru nova-fine-tune-repo	hyperpod start-job\ -n kubeflow\ --resep baik-baik saja- -:SM-HP-SFT-V2-terbaru"} 'tuning/nova/nova_2_0/nova_lite/SFT/nova_lite_2_0_p5_gpu_sft \ --override-parameters { "instance_type": "ml.p5.48xlarge", "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/novafine-tune-repo

Model	Teknik	Subkategori	URI citra	Perintah Peluncur Hyperpod
Nova 2.0	Penyetelan halus	Pembagian Data SFT MM+	708977205387.dkr.ecr.us-east-1.amazonaws.com/:SM-HP-SFT-V2-Dat aMixing-terbaru nova-fine-tune-repo	hyperpod start-job\ -n kubeflow \ --resep baik-baik saja- -:SM-HP-SFT-V2-Dat aMixing-terbaru"} 'tuning/nova/ forge/nova_2_0 /nova_lite/SFT/ nova_lite_2_0_p5_gpu_sft_mm_with_datamix \ -- override-parameters '{ "instance_type": "ml.p5.48xlarge", "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/novafine-tune-repo

Setelah Anda semua setup, mulai dari root sagemaker-hyperpod-cli repositori, navigasikan ke folder resep nova sft default

- `cd/src/hyperpod_cli/sagemaker_hyperpod_recipes/recipes_collection/recipes/training/nova/`
- Di sini Anda dapat memilih apakah Anda ingin menjalankan resep nova 1 atau nova 2 berdasarkan pilihan model dasar.

Untuk Nova 2.0 sft:

- Jika Anda ingin menggunakan pekerjaan sft biasa, Anda harus dapat melihat satu resep di bawah folder ini
 - `cd/src/hyperpod_cli/sagemaker_hyperpod_recipes/recipes_collection/recipes/fine-tuning/nova_2_0/nova_lite/SFT` dan kemudian Anda harus dapat melihat satu resep di bawah folder ini bernama `nova_lite_2_0_p5x8_gpu_sft.yaml`
- Jika Anda ingin menggunakan datamixing sft Job, Anda dapat menavigasi ke folder resep sft Forge
 - `cd/src/hyperpod_cli/sagemaker_hyperpod_recipes/recipes_collection/recipes/fine-tuning/nova/forge/nova_2_0/nova_lite/SFT` dan Anda seharusnya dapat melihat satu resep di bawah folder ini bernama: `nova_lite_2_0_p5x8_gpu_sft_with_datamix.yaml`
- Edit bagian dalam resep yang diperlukan oleh pekerjaan seperti `name`, `data_s3_path`, `validation_s3_path`, `output_s3_path`, dan `max_steps`. Karena kami melakukan sft, gagasan tentang zaman tidak berlaku di sini.

Konfigurasi pencampuran data akan terlihat sama, tetapi dengan bagian pencampuran data tambahan di bagian bawah yang mirip dengan ini

```
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

```

Ada dua kategori data tingkat atas di sini:

- **nova_data:** Ini adalah pencampuran data aktual dan dibagi lagi menjadi lebih banyak kategori. Sangat penting bahwa mereka berjumlah hingga 100%
 - Rincian lengkap dari kategori ini termasuk jumlah token dapat ditemukan di bawah
- **customer_data:** Ini adalah data pelatihan Anda yang dirujuk dalam kunci `data_s3_path` di bagian atas yaml Anda. Persentase yang diberikan di sini menentukan berapa persentase yang dihasilkan untuk `nova_data`. Misalnya, dalam pilihan persen di atas, selama pelatihan kami akan menggunakan 25% `customer_data` dan 75% `nova_data` yang 15% akan menjadi agen, 15% akan menjadi, 15% akan ilmiah business-and-finance, 15% akan menjadi kode, dan 15% akan menjadi factual-and-news

Tip: Jalankan `pip install -e.` sekali lagi dan Anda siap untuk mengirimkan pekerjaan Anda!

Kami akan mengesampingkan beberapa parameter di sini untuk menggunakan pencampuran data:

```

hyperpod start-job \
-n kubeflow \
--recipe fine-tuning/nova/forged/nova_2_0/nova_lite/SFT/
nova_lite_2_0_p5x8_gpu_sft_with_datamix \
--override-parameters '{
  "instance_type": "ml.p5.48xlarge",
  "recipes.run.name": "nova-sft-datamixing",
  "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-
SFT-V2-Datamix",
  "recipes.run.data_s3_path": "s3://sft-data/sft_train_data.jsonl",
  "recipes.run.validation_data_s3_path": "s3://sft-data/sft_val_data.jsonl",
  "recipes.run.output_s3_path": "s3://sft-data/output/
}'

```

Output Anda harus berisi nama pekerjaan sebagai berikut:

```
# MY Desktop # % hyperpod start-job \
```

```
-n kubeflow \
--recipe training/nova/forged/nova_2_0/nova_lite/sft/
nova_lite_2_0_p5x8_gpu_pretrain_with_datamix \
--override-parameters '{
  "instance_type": "ml.p5.48xlarge",
  "recipes.run.name": "nova-sft-datamixing",
  "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-fine-tune-repo:SM-HP-
SFT-V2-Datamix",
  "recipes.run.data_s3_path": "s3://sft-data/sft_train_data.jsonl",
  "recipes.run.validation_data_s3_path": "s3://sft-data/sft_val_data.jsonl",
  "recipes.run.output_s3_path": "s3://sft-data/output/
}'
```

Output akan seperti ini:

```
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"
```

```
}
```

Anda dapat melihat status pekerjaan Anda menggunakan `hyperpod list-pods -n kubeflow --job-name my-sft-run-wzdyn`

```
hyperpod list-pods -n kubeflow --job-name my-sft-run-wzdyn
{
  "pods": [
    {
      "PodName": "my-sft-run-wzdyn-master-0",
      "Namespace": "kubeflow",
      "Status": "Pending",
      "CreationTime": "2025-08-26 16:21:06+00:00"
    },
    {
      "PodName": "my-sft-run-wzdyn-worker-0",
      "Namespace": "kubeflow",
      "Status": "Pending",
      "CreationTime": "2025-08-26 16:21:06+00:00"
    }
  ]
}
```

atau langsung gunakan perintah `kubectl` untuk menemukannya.

Misalnya,

```
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>

Kiat pro: Pastikan untuk selalu menggunakan flag `-o wide` karena simpul EKS tempat pekerjaan berjalan akan membantu Anda menemukan log Anda lebih cepat di AWS UI

Cara Memantau Job

Anda dapat melihat log Anda salah satu dari tiga cara:

a) Menggunakan CloudWatch

Log Anda tersedia di akun Amazon Web Services Anda yang berisi kluster hyperpod di bawahnya CloudWatch. Untuk melihatnya di browser Anda, navigasikan ke CloudWatch beranda di akun Anda dan cari nama cluster Anda. Misalnya, jika kluster Anda dipanggil `my-hyperpod-rig`, grup log akan memiliki awalan:

- Grup log: `/aws/sagemaker/Clusters/my-hyperpod-rig/ {UUID}`
- Setelah Anda berada di grup log, Anda dapat menemukan log spesifik Anda menggunakan ID instance node seperti `- hyperpod-i-00b3d8a1bf25714e4`.
 - `i-00b3d8a1bf25714e4` di sini mewakili nama mesin ramah hyperpod tempat pekerjaan pelatihan Anda berjalan. Ingat bagaimana pada perintah sebelumnya `kubectl get pods -o wide -w -n kubeflow | (head -n1; grep)` output kita menangkap sebuah kolom bernama `NODE`. `my-cpt-run`
 - Run node “master” dalam hal ini berjalan pada `hyperpod-i-00b3d8a1bf25714e4` dan dengan demikian kita akan menggunakan string itu untuk memilih grup log untuk dilihat. Pilih salah satu yang mengatakan `SagemakerHyperPodTrainingJob /rig-group/ [NODE]`

Log Anda akan terlihat seperti ini:

b) Menggunakan CloudWatch Wawasan

Jika Anda memiliki nama pekerjaan yang berguna dan tidak ingin melalui semua langkah di atas, Anda cukup menanyakan semua log di bawah `/aws/sagemaker/Clusters/my-hyperpod-rig/ {UUID}` untuk menemukan log individu.

CPT

```
fields @timestamp, @message, @logStream, @log
| filter @message like /(?!i)Starting CPT Job/
| sort @timestamp desc
| limit 100
```

Untuk penyelesaian pekerjaan ganti Memulai SFT Job dengan SFT Job selesai

Kemudian Anda dapat mengklik hasil dan memilih salah satu yang mengatakan "Epoch 0" karena itu akan menjadi node master Anda.

C) Menggunakan aws cli

Anda dapat memilih untuk mengekor log Anda menggunakan. Sebelum melakukannya, periksa versi aws cli Anda menggunakan `aws --version`. Disarankan juga untuk menggunakan skrip utilitas ini yang membantu dalam pelacakan log langsung di terminal Anda

untuk V1:

```
aws logs get-log-events \
  --log-group-name /aws/sagemaker/YourLogGroupName \
  --log-stream-name YourLogStream \
  --start-from-head | jq -r '.events[].message'
```

untuk V2:

```
aws logs tail /aws/sagemaker/YourLogGroupName \
  --log-stream-name YourLogStream \
  --since 10m \
  --follow
```

D) Mengatur Aliran ML:

Anda dapat melacak metrik melalui MLFlow.

Buat MLflow aplikasi

Menggunakan UI Studio: Jika Anda membuat pekerjaan pelatihan melalui UI Studio, MLflow aplikasi default dibuat secara otomatis dan dipilih secara default di bawah Opsi Lanjutan.

Menggunakan CLI: Jika Anda menggunakan CLI, Anda harus membuat MLflow aplikasi dan meneruskannya sebagai input ke permintaan API pekerjaan pelatihan.

```
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)
```

Akses MLflow aplikasi

Menggunakan CLI: Buat URL yang telah ditentukan sebelumnya untuk mengakses UI aplikasi: MLflow

```
aws sagemaker create-presigned-mlflow-app-url \
  --arn $mlflow_app_arn \
  --region $region \
  --output text
```

Setelah ML Flow disiapkan, Anda dapat meneruskan URI dalam resep Anda atau menggunakan override saat memulai pekerjaan. Salah satu contoh cara melakukannya dapat ditemukan di README.

Bagaimana cara mengevaluasi model Anda setelah SFT?

Prasyarat

- Checkpoint S3 URI dari file manifest.json pekerjaan pelatihan Anda (untuk model terlatih)
- Dataset evaluasi diunggah ke S3 dalam format yang benar
- Output jalur S3 untuk hasil evaluasi

Tolok ukur di luar kotak: Gunakan tolok ukur di luar kotak untuk memvalidasi kinerja pada tugas umum. Untuk lebih jelasnya, periksa di sini.

Bawa data Anda sendiri:

Anda juga dapat menyediakan data kustom Anda dengan memformatnya dalam format di bawah ini dan kemudian menggunakan wadah yang disebutkan di bawah ini untuk mendapatkan hasil inferensi bersama dengan probabilitas log untuk kalibrasi jika diperlukan.

Peti jsonl per tugas dengan struktur berikut:

```
{
  "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"
}
```

Output yang dihasilkan selama fase inferensi pekerjaan evaluasi akan memiliki struktur sebagai berikut:

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

Deskripsi bidang:

- prompt: Masukan diformat dikirim ke model
- inferensi: Respons yang dihasilkan model
- gold: Diharapkan jawaban yang benar dari dataset input, bidang respons dari input
- metadata: Metadata opsional dilewatkan dari input

Siapkan Evaluasi Config

Perintah untuk meluncurkan pekerjaan evaluasi. Gunakan “--override-parameters” untuk memodifikasi entri apa pun dari resep.

```
hyperpod start-job -n kubeflow \
  --recipe evaluation/nova/nova_micro_p5_48x1_bring_your_own_dataset_eval \
  --override-parameters '{
```

```
"instance_type": "p5.48xlarge",
"container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/nova-evaluation-repo:SM-HP-Eval-latest",
"recipes.run.name": "<your-eval-job-name>",
"recipes.run.model_name_or_path": "<checkpoint-s3-uri>",
"recipes.run.output_s3_path": "s3://<your-bucket>/eval-results/",
"recipes.run.data_s3_path": "s3://<your-bucket>/eval-data.jsonl"
}'
```

Luncurkan Job Evaluasi Anda

Perintah peluncuran Job untuk berbagai resep dengan gambar yang sesuai.

Evaluasi Perintah Peluncuran Job

Model	Teknik	Subkategori	URI citra	Perintah
Nova 2.0	Evaluasi	Eval	708977205387.dkr.ecr.us-east-1.amazonaws.com/:SM-HP-Eval-terbaru nova-evaluation-repo	hyperpod start-job -n kubeflow\ --recipe -evaluation-repo:SM-HP-eval-latest"} 'evaluation/nova/nova_2_0/nova_lite/nova_lite_2_0_p5_48xl_gpu_ft_eval \ --override-parameters '{ "instance_type": "ml.p5.48xlarge", "container": "708977205387.dkr.ecr.us-east-1.amazonaws.com/nova

Pelajaran dan Tips

- Kualitas dataset SFT sangat penting. Anda harus melakukan segala upaya untuk menyaring data berkualitas rendah. Jika Anda memiliki subset kecil dari data berkualitas sangat tinggi—dalam hal kompleksitas dan akurasi—Anda dapat mempertimbangkan untuk menempatkannya menjelang akhir pelatihan untuk membantu model bertemu dengan lebih baik.
- Kami memanfaatkan kumpulan data teks dan multimodal (MM) untuk pencampuran data. Eksperimen kami dengan kumpulan data teks menunjukkan bahwa menambahkan kategori “reasoning-instruction-following” milik Nova secara signifikan meningkatkan kinerja di seluruh tolok ukur umum. Sebaiknya sertakan kategori ini dalam strategi pencampuran data Anda jika Anda peduli dengan tolok ukur generik yang mengalami regresi setelah Anda melakukan SFT dengan kumpulan data Anda.
- Untuk kumpulan data MM, eksperimen kami menunjukkan bahwa memasukkan lebih dari 20% kategori video ke dalam campuran bermanfaat untuk mempertahankan kinerja tolok ukur generik.
- Selanjutnya, SFT dengan pencampuran data cukup sensitif terhadap tingkat pembelajaran sehingga temuan kami menyarankan untuk menyesuaikan dengan tingkat pembelajaran default yaitu $1e-5$ untuk LoRa dan $5e-6$ untuk FR.
- Akhirnya, ada pertukaran antara latensi dan kinerja jika Anda mencampur kumpulan data milik Nova sehingga temuan kami menyarankan untuk mencampur 50% secara maksimal sebagai keseimbangan yang baik.

Pembelajaran Penguatan

Note

Dokumentasi rinci disediakan setelah berlangganan

Nova Forge menyediakan kemampuan pembelajaran penguatan tingkat lanjut dengan opsi untuk menggunakan fungsi hadiah jarak jauh di lingkungan Anda sendiri. Pelanggan dapat memilih untuk mengintegrasikan titik akhir mereka sendiri untuk mengeksekusi validasi untuk umpan balik dunia nyata langsung, atau bahkan menggunakan orkestrator mereka sendiri untuk mengoordinasikan evaluasi multi-putaran agen di lingkungan Anda.

Bawa orkestrator Anda sendiri untuk evaluasi multi-putaran agen

Untuk pengguna Forge yang membutuhkan percakapan multi-putaran atau fungsi hadiah melebihi batas waktu 15 menit, Nova Forge menyediakan kemampuan Bring Your Own Orchestration (BYOO). Ini memungkinkan Anda untuk mengoordinasikan evaluasi multi-putaran agen di lingkungan Anda (misalnya, menggunakan alat kimia untuk menilai desain molekuler, atau simulasi robotika yang menghargai penyelesaian tugas yang efisien dan menghukum tabrakan).

Topik

- [Gambaran umum arsitektur](#)
- [Pengaturan dan eksekusi](#)

Gambaran umum arsitektur

Arsitektur BYOO memberikan kontrol penuh atas proses peluncuran dan pembuatan melalui infrastruktur yang dikelola pelanggan.

Pelatihan VPC:

- Peluncuran: Mengoordinasikan pelatihan dengan mendelegasikan generasi peluncuran ke infrastruktur pelanggan
- Pelatih: Melakukan pembaruan bobot model berdasarkan peluncuran yang diterima

VPC Pelanggan (seperti ECS pada EC2):

- Proxy Lambda: Menerima permintaan peluncuran dan berkoordinasi dengan infrastruktur pelanggan
- Rollout Response SQS: Antrian untuk mengembalikan peluncuran yang telah selesai ke infrastruktur pelatihan
- Hasilkan Permintaan SQS: Antrian untuk permintaan pembuatan model
- Hasilkan Respons SQS: Antrian untuk respons pembuatan model
- Wadah Pelanggan: Menerapkan logika orkestrasi khusus (dapat menggunakan starter kit yang disediakan)
- DynamoDB: Menyimpan dan mengambil status di seluruh proses orkestrasi

Alur kerja:

1. Peluncuran mendelegasikan generasi peluncuran ke Proxy Lambda
2. Proxy Lambda mendorong permintaan API peluncuran untuk Menghasilkan Permintaan SQS
3. Kontainer pelanggan memproses permintaan, mengelola interaksi multi-putaran, dan memanggil fungsi hadiah
4. Container menyimpan dan mengambil status dari DynamoDB sesuai kebutuhan
5. Container mendorong respons peluncuran ke Rollout Response SQS
6. Peluncuran mengirimkan peluncuran yang telah selesai ke Trainer untuk pembaruan berat badan

Pengaturan dan eksekusi

Untuk petunjuk penyiapan terperinci, konfigurasi resep, format permintaan dan respons, dan contoh lingkungan, lihat dokumentasi rahasia yang diberikan kepada pelanggan Nova Forge. Untuk mendapatkan dokumen Nova Forge ikuti langkah-langkah di bawah ini:

```
aws s3 cp s3://nova-forge-c7363-206080352451-us-east-1/v1/ ./ --recursive
```

Setelah aset diunduh, Anda dapat menemukan semua dokumentasi di bawah docs folder.

Toolkit AI yang bertanggung jawab dan moderasi konten

Toolkit AI yang bertanggung jawab

Nova Forge menyediakan Toolkit AI Bertanggung Jawab yang mencakup data pelatihan dan evaluasi untuk menyelaraskan model dengan pedoman AI Amazon Nova yang bertanggung jawab selama proses pelatihan, dan kontrol runtime untuk memoderasi respons model selama inferensi.

Data pelatihan — Kasus dan skenario yang menekankan prinsip AI yang bertanggung jawab, pertimbangan keselamatan, dan penyebaran teknologi yang bertanggung jawab tersedia untuk pencampuran data guna menyelaraskan model secara bertanggung jawab selama pra-pelatihan lanjutan.

Evaluasi — Evaluasi yang menguji kemampuan model untuk mendeteksi dan menolak konten yang tidak pantas, berbahaya, atau salah tersedia sebagai tugas patokan untuk menentukan delta antara kinerja model dasar dan kinerja model khusus.

Kontrol runtime — Secara default, runtime Amazon Nova mengontrol respons model moderat selama inferensi. Untuk mengubah kontrol runtime ini, minta Pengaturan Moderasi Konten yang Dapat Disesuaikan Amazon Nova dengan menghubungi manajer akun. AWS

Keselamatan adalah tanggung jawab bersama antara AWS dan penggunanya. Mengubah model dasar atau menggunakan pra-pelatihan lanjutan untuk meningkatkan kinerja pada kasus penggunaan tertentu dapat memengaruhi keselamatan, keadilan, dan properti lain dari model baru. Metode adaptasi yang kuat meminimalkan perubahan pada keselamatan, keadilan, dan perlindungan lain yang dibangun ke dalam model dasar sambil meminimalkan dampak pada kinerja model untuk tugas-tugas yang tidak disesuaikan untuk model. End-to-end pengujian aplikasi pada kumpulan data yang mewakili kasus penggunaan diperlukan untuk menentukan apakah hasil pengujian memenuhi harapan spesifik keamanan, keadilan, dan properti lainnya, serta efektivitas keseluruhan. Untuk informasi selengkapnya, lihat Panduan Penggunaan AI yang Bertanggung Jawab Amazon Web Services, Kebijakan AI Bertanggung Jawab Amazon Web Services, Kebijakan Penggunaan yang Dapat Diterima Amazon Web Services, dan Ketentuan Layanan Amazon Web Services.

Penggunaan yang bertanggung jawab

Membangun langkah-langkah keselamatan, keamanan, dan kepercayaan dengan model AI adalah tanggung jawab bersama antara AWS dan pelanggan kami. Tujuan kami adalah menyelaraskan model kami dengan [Kebijakan Penggunaan yang AWS Dapat Diterima](#) dan mengurangi hasil yang tidak diinginkan sambil memberikan pengalaman pelanggan yang menyenangkan. Pendekatan kami terhadap Responsible AI (RAI) disusun berdasarkan [dimensi inti AI yang bertanggung jawab](#), yang tercakup dalam daftar berikut. Untuk masing-masing dimensi ini, kami mengembangkan pedoman yang mengatur pengambilan keputusan kami di seluruh siklus hidup pengembangan model. Siklus hidup ini mencakup setiap tahap, mulai dari pengumpulan data awal dan pra-pelatihan, hingga implementasi mitigasi runtime pasca-penerapan.

- Keadilan - Mempertimbangkan dampak pada berbagai kelompok pemangku kepentingan
- Keterjelasan - Memahami dan mengevaluasi output sistem
- Privasi dan Keamanan - Memperoleh, menggunakan, dan melindungi data dan model dengan tepat
- Keamanan - Mencegah keluaran dan penyalahgunaan yang berbahaya
- Controllability - Memiliki mekanisme untuk memantau dan mengarahkan perilaku sistem AI
- Kebenaran dan ketahanan - Mencapai output sistem yang benar, bahkan dengan input yang tidak terduga atau permusuhan
- Tata Kelola - Memasukkan praktik terbaik ke dalam rantai pasokan AI, termasuk penyedia dan deployer
- Transparansi - Memungkinkan pemangku kepentingan untuk membuat pilihan berdasarkan informasi tentang keterlibatan mereka dengan sistem AI

Pedoman

Pedoman yang kami gunakan untuk mengarahkan pengembangan model kami mencakup tetapi tidak terbatas pada memoderasi konten yang memuliakan, memfasilitasi, atau mempromosikan hal-hal berikut:

- Partisipasi dalam kegiatan berbahaya, melukai diri sendiri, atau penggunaan zat berbahaya.
- Penggunaan, penyalahgunaan, atau perdagangan zat yang dikendalikan, tembakau, atau alkohol.
- Kekerasan fisik atau darah kental.

- Pelecehan anak atau materi pelecehan seksual anak.
- Pelecehan hewan atau perdagangan hewan.
- Informasi yang salah yang memposisikan individu atau kelompok sebagai orang yang bertanggung jawab atas penipuan yang disengaja, merusak institusi dengan kredibilitas publik umum, atau membahayakan kesehatan atau mata pencaharian manusia.
- Malware, konten berbahaya, atau konten apa pun yang memfasilitasi kejahatan dunia maya.
- Tidak hormat, diskriminasi, atau stereotip terhadap individu atau kelompok.
- Penghinaan, kata-kata kotor, gerakan cabul, bahasa eksplisit seksual, pornografi, simbol kebencian, atau kelompok kebencian.
- Ketelanjangan penuh yang berada di luar konteks ilmiah, pendidikan, atau referensi.
- Bias terhadap kelompok berdasarkan karakteristik demografis.

Rekomendasi

Kesesuaian untuk Digunakan: Karena keluaran model AI bersifat probabilistik, Amazon Nova dapat menghasilkan konten yang tidak akurat atau tidak pantas. Pelanggan harus mengevaluasi output untuk akurasi dan kesesuaian untuk kasus penggunaan mereka, terutama jika mereka akan langsung muncul ke pengguna akhir. Selain itu, jika Amazon Nova digunakan dalam alur kerja pelanggan yang menghasilkan keputusan konsekuensial, pelanggan harus mengevaluasi potensi risiko kasus penggunaan mereka dan menerapkan pengawasan manusia yang tepat, pengujian, dan perlindungan khusus kasus penggunaan lainnya untuk mengurangi risiko tersebut.

Optimasi Cepat: Jika terjadi moderasi oleh Amazon Nova, pertimbangkan untuk memeriksa petunjuk yang digunakan sehubungan dengan pedoman di atas. Mengoptimalkan petunjuk untuk mengurangi kemungkinan menghasilkan hasil yang tidak diinginkan adalah strategi yang disarankan untuk menghasilkan output yang diharapkan menggunakan model Amazon Nova. Perhatikan di mana input dikendalikan oleh pengguna, termasuk konten piksel yang dapat memengaruhi kinerja model. Silakan lihat bagian panduan cepat di panduan pengguna ini untuk detail lebih lanjut.

Privasi: Amazon Nova tersedia di Amazon Bedrock. Amazon Bedrock adalah layanan terkelola dan tidak menyimpan atau meninjau permintaan pelanggan atau penyelesaian yang cepat dan permintaan dan penyelesaian pelanggan tidak pernah dibagi antara pelanggan, atau dengan mitra. Amazon Bedrock AWS tidak menggunakan input atau output yang dihasilkan melalui Amazon Bedrock layanan untuk melatih Amazon Bedrock model, termasuk Amazon Nova. Lihat Bagian [50.3](#) dari Ketentuan AWS Layanan dan [FAQ Privasi AWS Data](#) untuk informasi selengkapnya. Untuk

informasi privasi khusus layanan, lihat bagian Privasi dan Keamanan pada dokumentasi. [Amazon Bedrock FAQs](#) Amazon Nova mengambil langkah-langkah untuk menghindari menyelesaikan permintaan yang dapat ditafsirkan sebagai meminta informasi pribadi. Jika pengguna khawatir bahwa informasi pribadi mereka telah dimasukkan dalam penyelesaian Amazon Nova, pengguna harus menghubungi kami [di sini](#).

Keamanan: Semua Amazon Bedrock model, termasuk Amazon Nova, hadir dengan keamanan perusahaan yang memungkinkan pelanggan membangun aplikasi AI generatif yang mendukung standar keamanan dan kepatuhan data umum, termasuk GDPR dan HIPAA. Pelanggan dapat menggunakan AWS PrivateLink untuk membangun konektivitas pribadi antara Amazon Nova yang disesuaikan dan jaringan on-premise tanpa mengekspos lalu lintas pelanggan ke internet. Data pelanggan selalu dienkripsi dalam perjalanan dan saat istirahat dan pelanggan dapat menggunakan kunci mereka sendiri untuk mengenkripsi data, misalnya, menggunakan AWS Key Management Service. Pelanggan dapat menggunakan AWS Identity and Access Management untuk mengontrol akses ke Amazon Bedrock sumber daya dengan aman, termasuk Amazon Nova yang disesuaikan. Selain itu, Amazon Bedrock menawarkan kemampuan pemantauan dan pencatatan komprehensif yang dapat mendukung tata kelola pelanggan dan persyaratan audit. Misalnya, Amazon CloudWatch dapat membantu melacak metrik penggunaan yang diperlukan untuk tujuan audit dan AWS CloudTrail dapat membantu memantau aktivitas API dan memecahkan masalah karena Amazon Nova terintegrasi dengan sistem lain. AWS Pelanggan juga dapat memilih untuk menyimpan metadata, prompt, dan penyelesaian di bucket Amazon Simple Storage Service (Amazon S3) terenkripsi mereka sendiri.

Kekayaan Intelektual: AWS [menawarkan cakupan ganti rugi kekayaan intelektual \(IP\) yang tidak dibatasi untuk keluaran model Amazon Nova yang tersedia secara umum \(lihat Bagian 50.10 dari Ketentuan Layanan\)](#). Ini berarti bahwa pelanggan dilindungi dari klaim pihak ketiga yang menuduh pelanggaran atau penyalahgunaan IP (termasuk klaim hak cipta) oleh output yang dihasilkan oleh model Amazon Nova ini. Selain itu, ganti rugi IP standar kami untuk penggunaan Layanan melindungi pelanggan dari klaim pihak ketiga yang menuduh pelanggaran IP (termasuk klaim hak cipta) oleh Layanan (termasuk model Amazon Nova) dan data yang digunakan untuk melatih mereka.

Kuota untuk Amazon Nova

Anda Akun AWS memiliki kuota default, sebelumnya disebut sebagai batas, untuk Amazon Bedrock. Untuk melihat kuota layanan untuk Amazon Bedrock, lakukan salah satu hal berikut:

- Ikuti langkah-langkah di [Melihat kuota layanan](#) dan pilih Amazon Bedrock sebagai layanan.
- Lihat [titik akhir dan kuota Amazon Bedrock](#) di. Referensi Umum AWS

Note

Jika kuota ditandai sebagai tidak dapat disesuaikan melalui Service Quotas, Anda dapat mengirimkan permintaan melalui formulir [kenaikan batas](#) untuk dipertimbangkan untuk kenaikan.

Untuk menjaga kinerja layanan dan memastikan penggunaan Amazon Bedrock yang tepat, kuota default yang ditetapkan ke akun dapat diperbarui tergantung pada faktor regional, riwayat pembayaran, penggunaan penipuan, and/or persetujuan permintaan peningkatan kuota.

Minta kenaikan kuota Amazon Nova

Anda dapat meminta kenaikan kuota untuk akun Anda dengan mengikuti langkah-langkah di bawah ini:

- [Jika kuota ditandai sebagai Ya di kolom Adjustable di titik akhir Amazon Bedrock dan kuota di dalamnya Referensi Umum AWS, Anda dapat menyesuaikannya dengan mengikuti langkah-langkah di Meminta Peningkatan Kuota dalam Panduan Pengguna Service Quotas dalam Panduan Pengguna Service Quotas.](#)
- Kuota pemanggilan model On-Demand di [titik akhir Amazon Bedrock dan kuota di Referensi Umum AWS tidak dapat disesuaikan](#) melalui Service Quotas. Hubungi Akun AWS manajer Anda untuk dipertimbangkan untuk peningkatan.

 Note

Karena permintaan yang luar biasa, prioritas akan diberikan kepada pelanggan yang menghasilkan lalu lintas yang mengkonsumsi alokasi kuota yang ada. Permintaan Anda mungkin ditolak jika Anda tidak memenuhi persyaratan ini.

- Anda dapat mengirimkan permintaan melalui [formulir peningkatan batas](#) untuk dipertimbangkan untuk kenaikan meskipun kuota ditandai sebagai Tidak di kolom Adjustable di [titik akhir Amazon Bedrock dan kuota](#) di, Referensi Umum AWS

Pemantauan Amazon Nova

Pemantauan adalah bagian penting dalam menjaga keandalan, ketersediaan, dan kinerja Amazon Nova dan AWS solusi Anda yang lain. AWS menyediakan alat pemantauan berikut untuk menonton Amazon Nova, melaporkan ketika ada sesuatu yang salah dan mengambil tindakan otomatis bila perlu:

Karena Amazon Nova tersedia melalui Amazon Bedrock, ikuti semua panduan pemantauan di [Pantau kesehatan dan kinerja Amazon Bedrock](#).

Keamanan di Amazon Nova

Keamanan cloud di AWS adalah prioritas tertinggi. Sebagai AWS pelanggan, Anda mendapat manfaat dari pusat data dan arsitektur jaringan yang dibangun untuk memenuhi persyaratan organisasi yang paling sensitif terhadap keamanan.

Keamanan adalah tanggung jawab bersama antara Anda AWS dan Anda. [Model tanggung jawab bersama](#) menjelaskan hal ini sebagai keamanan dari cloud dan keamanan dalam cloud:

- Keamanan cloud — AWS bertanggung jawab untuk melindungi infrastruktur yang menjalankan AWS layanan di AWS Cloud. AWS juga memberi Anda layanan yang dapat Anda gunakan dengan aman. Auditor pihak ketiga secara teratur menguji dan memverifikasi efektivitas keamanan kami sebagai bagian dari [Program AWS Kepatuhan Program AWS Kepatuhan](#) . Untuk mempelajari tentang program kepatuhan yang berlaku untuk Amazon Nova, lihat [AWS Layanan dalam Lingkup berdasarkan AWS Layanan Program Kepatuhan](#) .
- Keamanan di cloud — Tanggung jawab Anda ditentukan oleh AWS layanan yang Anda gunakan. Anda juga bertanggung jawab atas faktor-faktor lain termasuk sensitivitas data Anda, persyaratan perusahaan Anda dan hukum dan peraturan yang berlaku.

Karena Amazon Nova tersedia melalui Amazon Bedrock, ikuti semua panduan keamanan di [Security in Amazon Bedrock](#).

Buat sumber daya Amazon Nova dengan AWS CloudFormation

Saat menerapkan model Amazon Nova melalui Amazon Bedrock dengan CloudFormation, ikuti semua CloudFormation panduan di Buat sumber daya [Amazon Bedrock](#) dengan. CloudFormation

Untuk informasi selengkapnya, termasuk contoh templat JSON dan YAMAL, lihat [YOUR-SERVICE-RESOURCE-TOPNODE-IN-CLOUDFORMATION YOUR-RESOURCE-PLURAL](#), ubah tautan ini di [file local-phrases.ent di](#) Panduan Pengguna.AWS CloudFormation

Pelajari lebih lanjut tentang CloudFormation

Untuk mempelajari selengkapnya CloudFormation, lihat sumber daya berikut:

- [AWS CloudFormation](#)
- [AWS CloudFormation Panduan Pengguna](#)
- [Referensi CloudFormation API](#)
- [AWS CloudFormation Panduan Pengguna Antarmuka Baris Perintah](#)

Riwayat dokumen untuk Panduan Pengembang Amazon Nova

Tabel berikut menjelaskan rilis dokumentasi untuk Amazon Nova 2.0.

Perubahan	Deskripsi	Tanggal
Rilis awal Amazon Nova 2.0	Rilis awal Panduan Pengembang Amazon Nova 2.0 dengan model-model baru: Nova 2 Lite, Amazon Nova Sonic dan. Panduan ini memperkenalkan kemampuan multimodal yang ditingkatkan, fitur penalaran, dan peningkatan kinerja di semua tingkatan model.	Desember 2, 2025

Terjemahan disediakan oleh mesin penerjemah. Jika konten terjemahan yang diberikan bertentangan dengan versi bahasa Inggris aslinya, utamakan versi bahasa Inggris.