

# AWS Black Belt Online Seminar

Amazon Bedrock Series #01

# Amazon Bedrock Overview

森下 裕介

Solutions Architect

2024/06



# 内容についての注意点

- 本資料では資料作成時点（2024年6月下旬）のサービス内容および価格についてご説明しています。AWSのサービスは常にアップデートを続けているため、最新の情報はAWS公式ウェブサイト (<https://aws.amazon.com/>) にてご確認ください
- 資料作成には十分注意しておりますが、資料内の価格とAWS公式ウェブサイト記載の価格に相違があった場合、AWS公式ウェブサイトの価格を優先とさせていただきます
- 価格は税抜表記となっております。日本居住者のお客様には別途消費税をご請求させていただきます
- 技術的な内容に関しましては、有料の [AWS サポート窓口](#) へお問い合わせください
- 料金面でのお問い合わせに関しましては、[カスタマーサポート窓口](#) へお問い合わせください (マネジメントコンソールへのログインが必要です)

# 森下 裕介 Morishita Yusuke



アマゾンウェブサービスジャパン合同会社  
ソリューションアーキテクト

製造業のお客様を中心に  
クラウドの技術支援を担当しています。

好きな AWS サービス：  
Amazon Bedrock  
Amazon Rekognition

苦手なもの：  
ハルシネーション  
ミニトマト

# 本動画の対象者とゴール

- 主な対象者

- これから AWS で 生成 AI の活用を始めたいと考えている方
- Amazon Bedrock のことを初めて学ぶ方
- Amazon Bedrock がもつ各種機能について知りたい方

- 本動画のゴール：

**Amazon Bedrock の Overview について理解する！**

Amazon Bedrock の個別機能の詳細については後続の Blackbelt でご紹介予定です。

# アジェンダ

- 生成 AI 活用をはじめる上での難しさ
- Amazon Bedrock の基本
- 生成 AI アプリ開発のよくある課題と Amazon Bedrock の各種機能
- まとめ

# 生成 AI 活用をはじめる上での難しさ



# 生成 AI とは

会話、ストーリー、画像、動画、音楽など、  
新しいコンテンツやアイデアを創造

基盤モデルと一般的に呼ばれる、膨大なデータで  
あらかじめ学習された大規模なモデルを原動力とする

# 生成 AI 活用をはじめる上での難しさ

## 生成 AI の進化への追従

複数のモデルを簡単に利用できる環境の構築



## インフラストラクチャ

モデルの実行を支えるインフラの管理

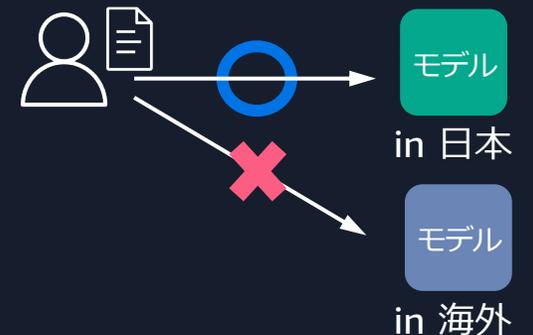


### 必要なこと

- 各モデルごとの環境整備と機械学習の知識
- モデルのデプロイやカスタマイズのための大規模な計算リソース
- インフラの維持管理
- 柔軟なスケーリング
- ...

## プライバシーとセキュリティ

データ漏洩の防止、国内にデータを留めたい



# 生成 AI 活用をはじめる上での難しさ

生成 AI の進化への追従

インフラストラクチャ

プライバシーと  
セキュリティ

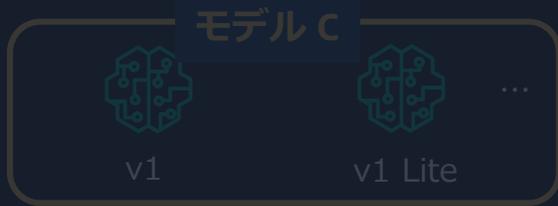
複数のモデルを簡単に

モデルの実行をマネジ

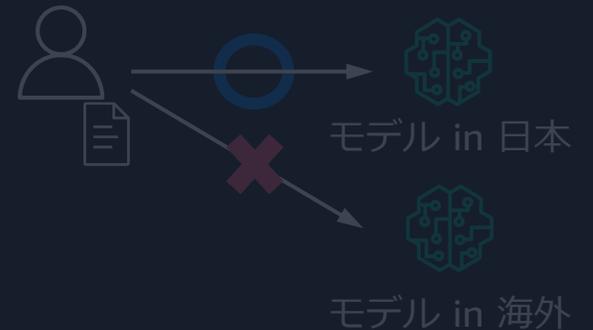
メントの混雑の防止

## それ、 Amazon Bedrock で解決できます！

パラメータ○B    パラメータ△B



- 各モデルごとの環境構築と機械学習の知識
- モデルのデプロイやカスタマイズのための大規模な計算リソース
- インフラの維持管理
- 柔軟なスケーリング
- ...



# Amazon Bedrock



基盤モデルを活用した  
生成 AI アプリケーションを  
簡単に構築、拡張できる方法



API を介してさまざまな基盤モデルにアクセス、  
インフラ管理は不要



お客様の業務用途に適した基盤モデルを選択  
Amazon, AI21 Labs, Anthropic, Cohere,  
Meta, Mistral, Stability AI, ...



データセキュリティやコンプライアンスを実現



エージェント機能、RAG 機能、非公開でのモデル  
のカスタマイズなど基盤モデルの効果を高める  
さまざまな機能を提供

東京リージョン含む国内外の AWS リージョンで一般提供中

# Amazon Bedrock の基本

2024年6月時点

# Amazon Bedrock

幅広い基盤モデルの選択肢をご提供

AI21 labs

ANTHROPIC



co:here

∞ Meta AI

stability.ai



JURASSIC

CLAUDE

MISTRAL  
& MIXTRAL

COMMAND  
& EMBED

LLAMA

SDXL

AMAZON TITAN

テキスト

テキスト  
& ビジョン

テキスト

テキスト

テキスト

画像

テキスト

Jamba-Instruct  
Jurassic-2 Ultra  
Jurassic-2 Mid

Claude 3.5 Sonnet  
Claude 3 Opus  
Claude 3 Sonnet  
Claude 3 Haiku

Mistral Large  
Mistral Small  
Mistral 7B  
Mixtral 8X7B

Command R+  
Command R  
Command  
Command Light

Llama 3 70B  
Llama 3 8B  
Llama 2 70B  
Llama 2 13B

Stable Diffusion XL 1.0

Titan Text Premier  
Titan Text Express  
Titan Text Lite

テキスト

Claude 2.1  
Claude 2.0  
Claude Instant

埋め込み

Embed - Multilingual  
Embed - English

画像

Titan Image Generator

埋め込み

Titan Multimodal Embeddings  
Titan Text Embeddings V2  
Titan Text Embeddings



# 基盤モデルの種類

様々なモダリティのデータを扱える基盤モデルの種類を提供

入力 (プロンプト)	基盤モデル	出力	
“日本で1番高い山は？”	テキスト	“富士山です。...”	入力テキストに対応するテキストを生成
 + “画像には何が写っていますか？”	テキスト & ビジョン	“これは富士山です。...”	テキスト入力だけでなく画像も入力可能なモデル
“富士山”	画像	 by Amazon Titan Image Generator	入力テキストに対応する画像を生成
 or “富士山”	埋め込み	[-0.00268, -0.03386,...]	入力を数値表現に変換 検索用途などで利用

# Amazon Bedrock の利用イメージ

基盤モデルをサーバーレスで提供しており  
アプリケーションから API を通じて利用



ユースケースに応じた  
お客様のアプリケーション  
(例: チャット Web アプリ)

**Amazon Bedrock は  
様々な基盤モデルをサーバーレスで提供**

# データセキュリティ・コンプライアンス



お客様のデータが  
モデルの学習や  
AWS およびサードパーティーの  
モデルプロバイダーに  
共有されることは無い

モデル入出力内容に対し  
人間による検閲が  
なされることは無い

お客様のデータはすべて作成  
されたリージョンに留まる



AWS PrivateLink により  
Amazon VPC と  
Amazon Bedrock 間の  
プライベート接続を実現

全ての転送・保管されるデータ  
は常に暗号化

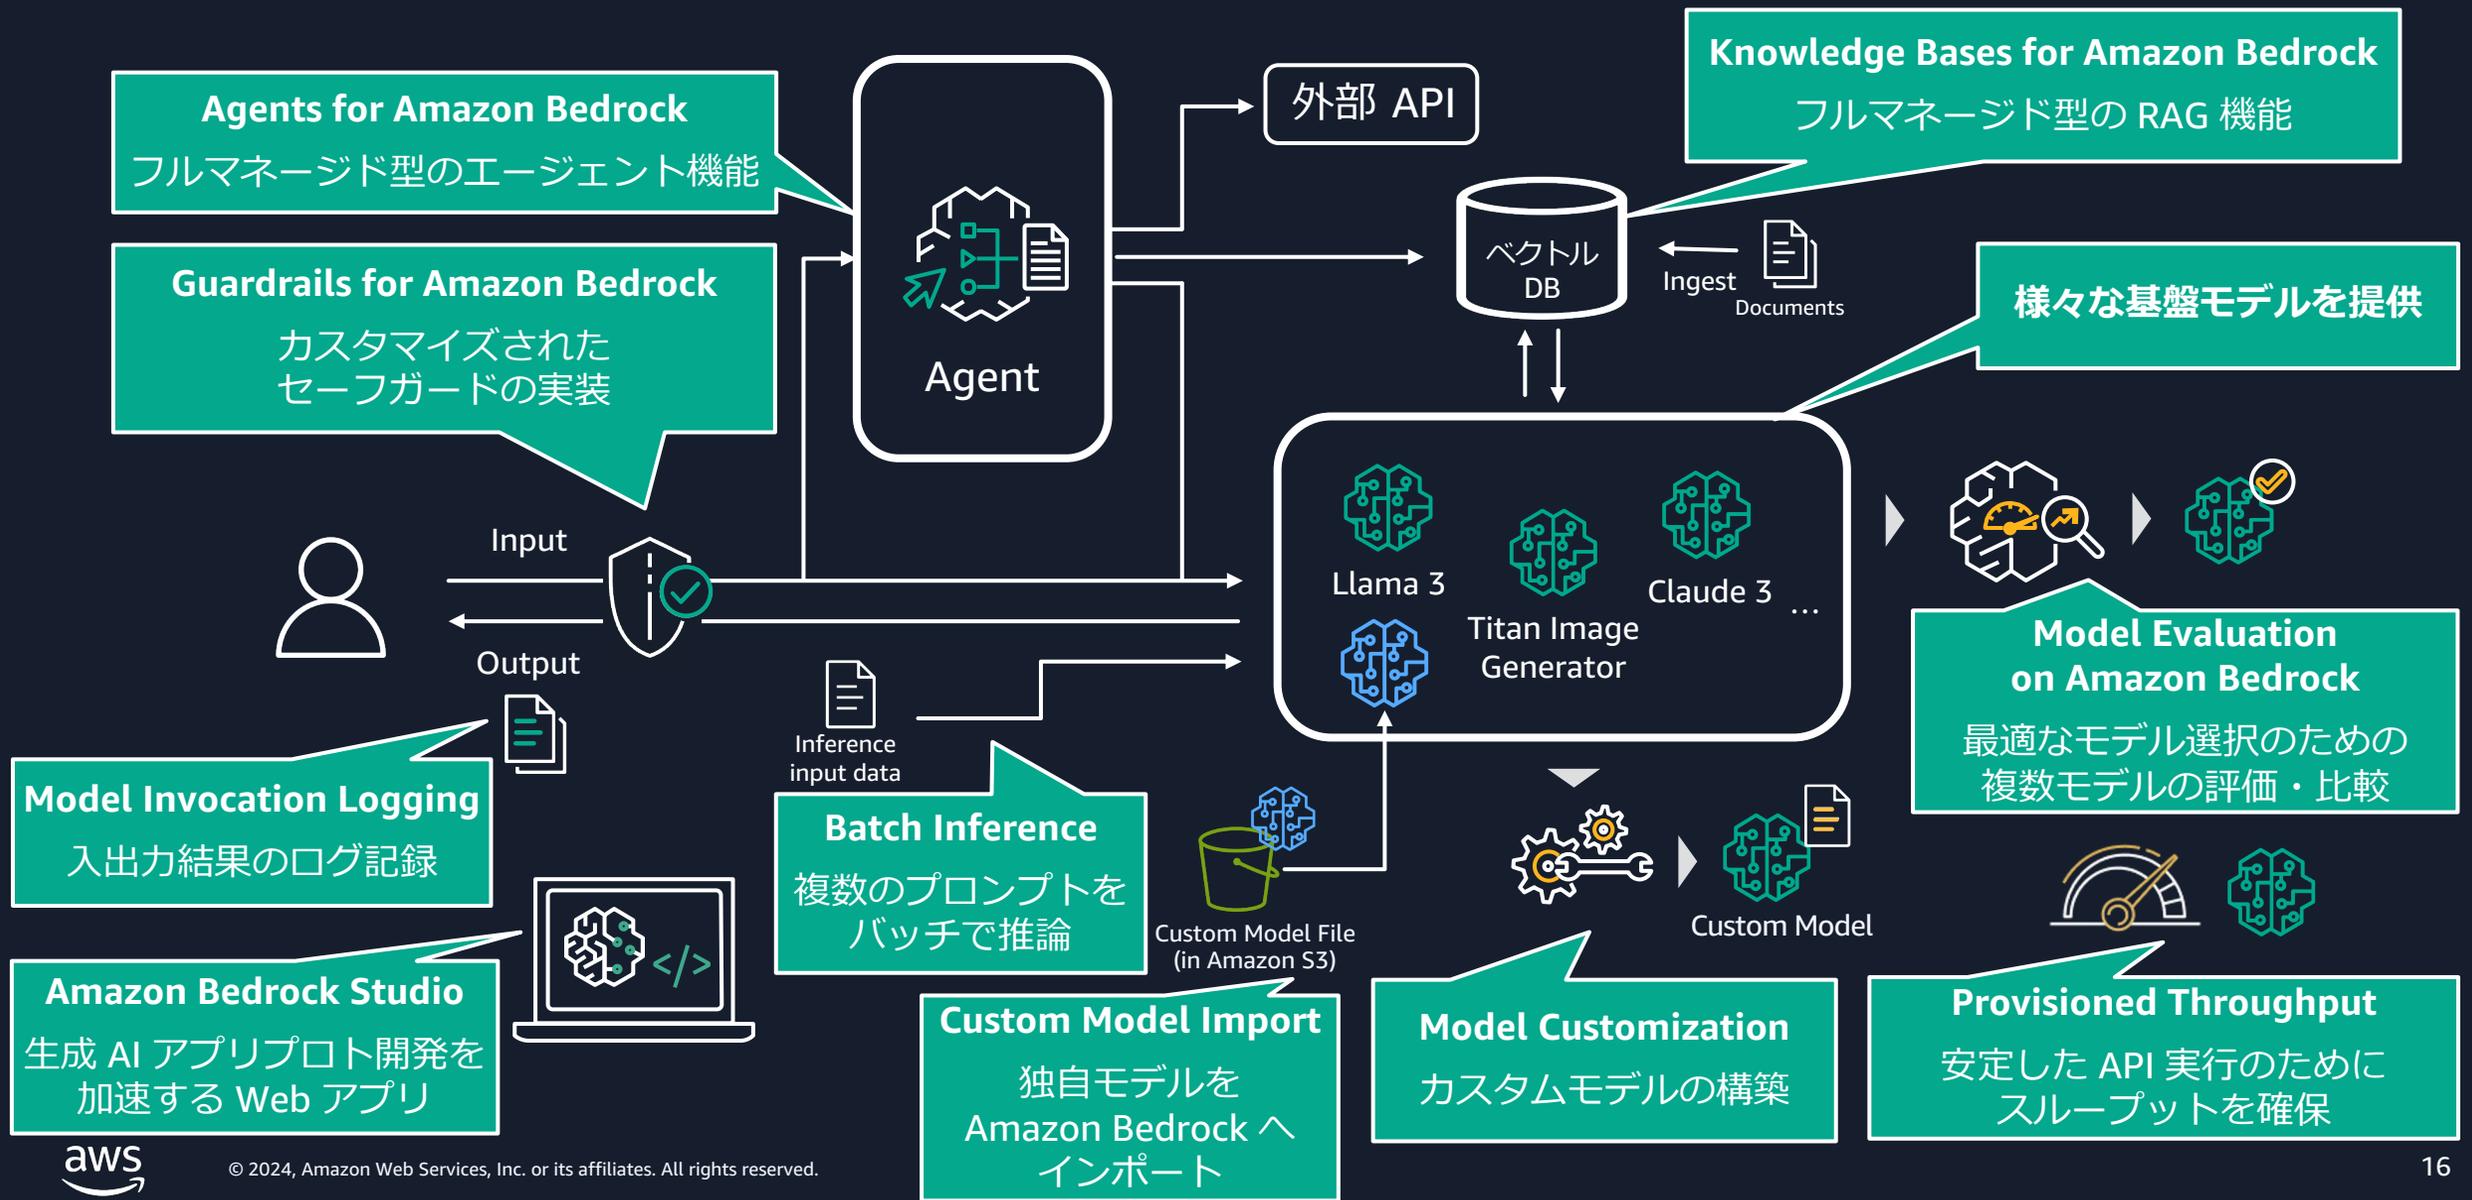


GDPR (一般データ保護規則)  
HIPAA コンプライアンス等  
標準規格に準拠

ISMAD の言明対象範囲に  
登録

# Amazon Bedrock の主な機能の全体像

2024年6月 ver.



# 生成 AI アプリ開発をサポートする Amazon Bedrock の各種機能

# 生成 AI アプリ開発でよくある課題

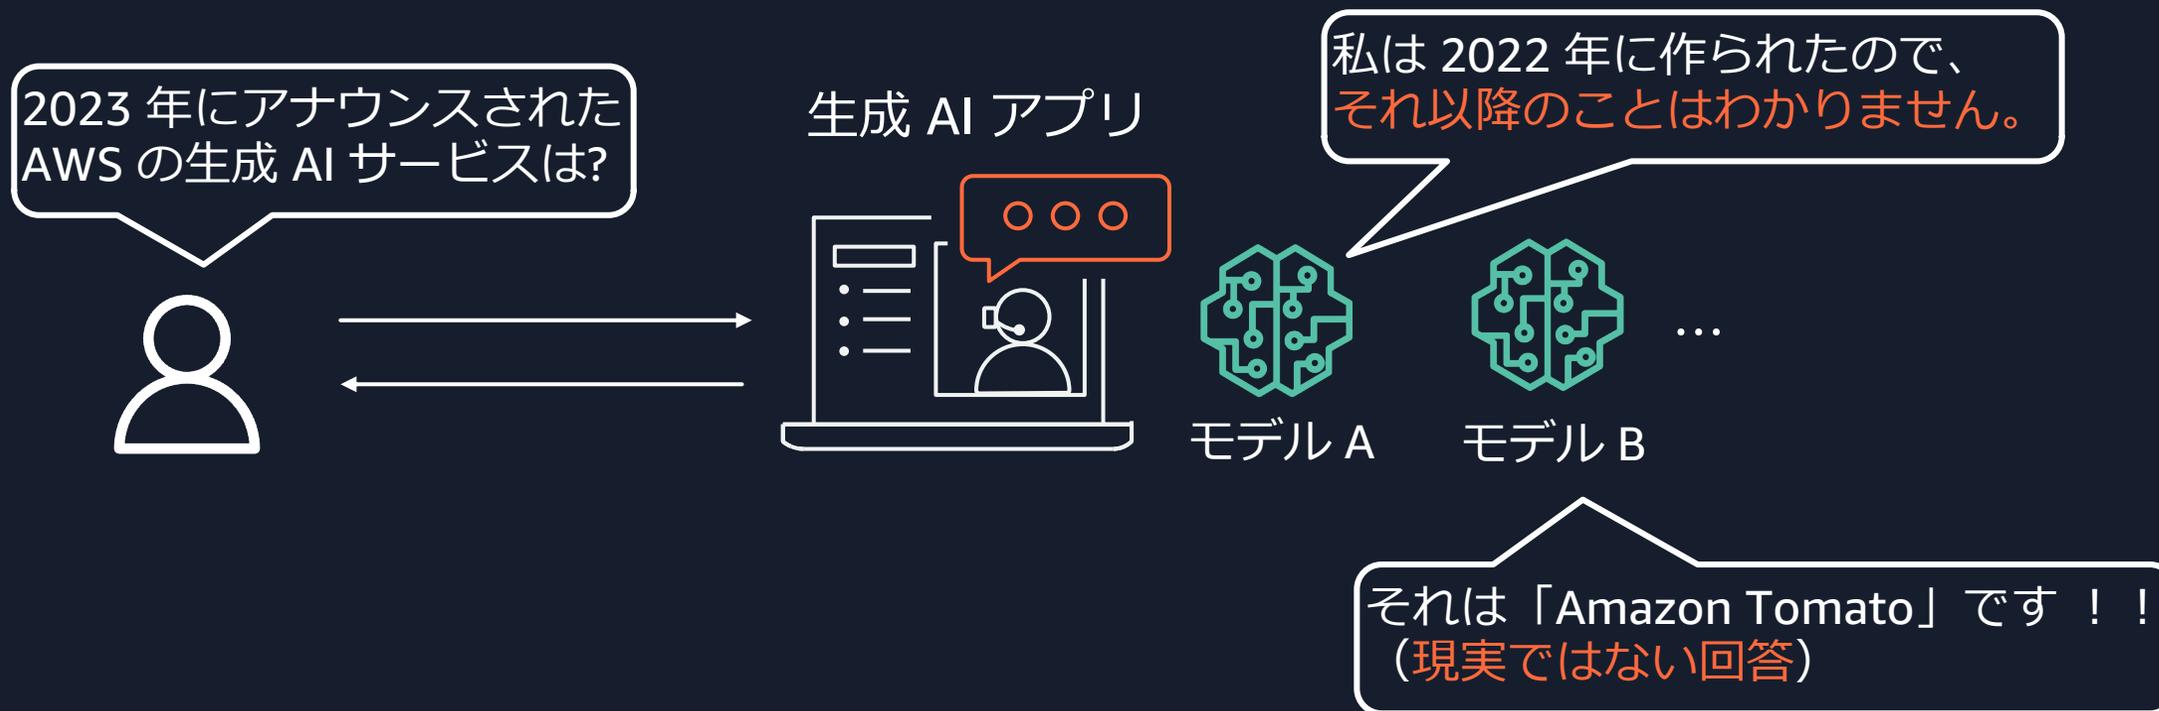
- 課題 1 : 独自データの活用
- 課題 2 : データや外部 API との連携の実現
- 課題 3 : 基盤モデルの評価と最適なモデルの選択
- 課題 4 : 生成 AI アプリの適切な利用状況の維持と安定的稼働
- 課題 5 : 生成 AI 活用のアイデアの迅速な実験と評価

# 生成 AI アプリ開発でよくある課題

- 課題 1 : 独自データの活用
- 課題 2 : データや外部 API との連携の実現
- 課題 3 : 基盤モデルの評価と最適なモデルの選択
- 課題 4 : 生成 AI アプリの適切な利用状況の維持と安定的稼働
- 課題 5 : 生成 AI 活用のアイデアの迅速な実験と評価

# よくある課題 1： 独自データの活用

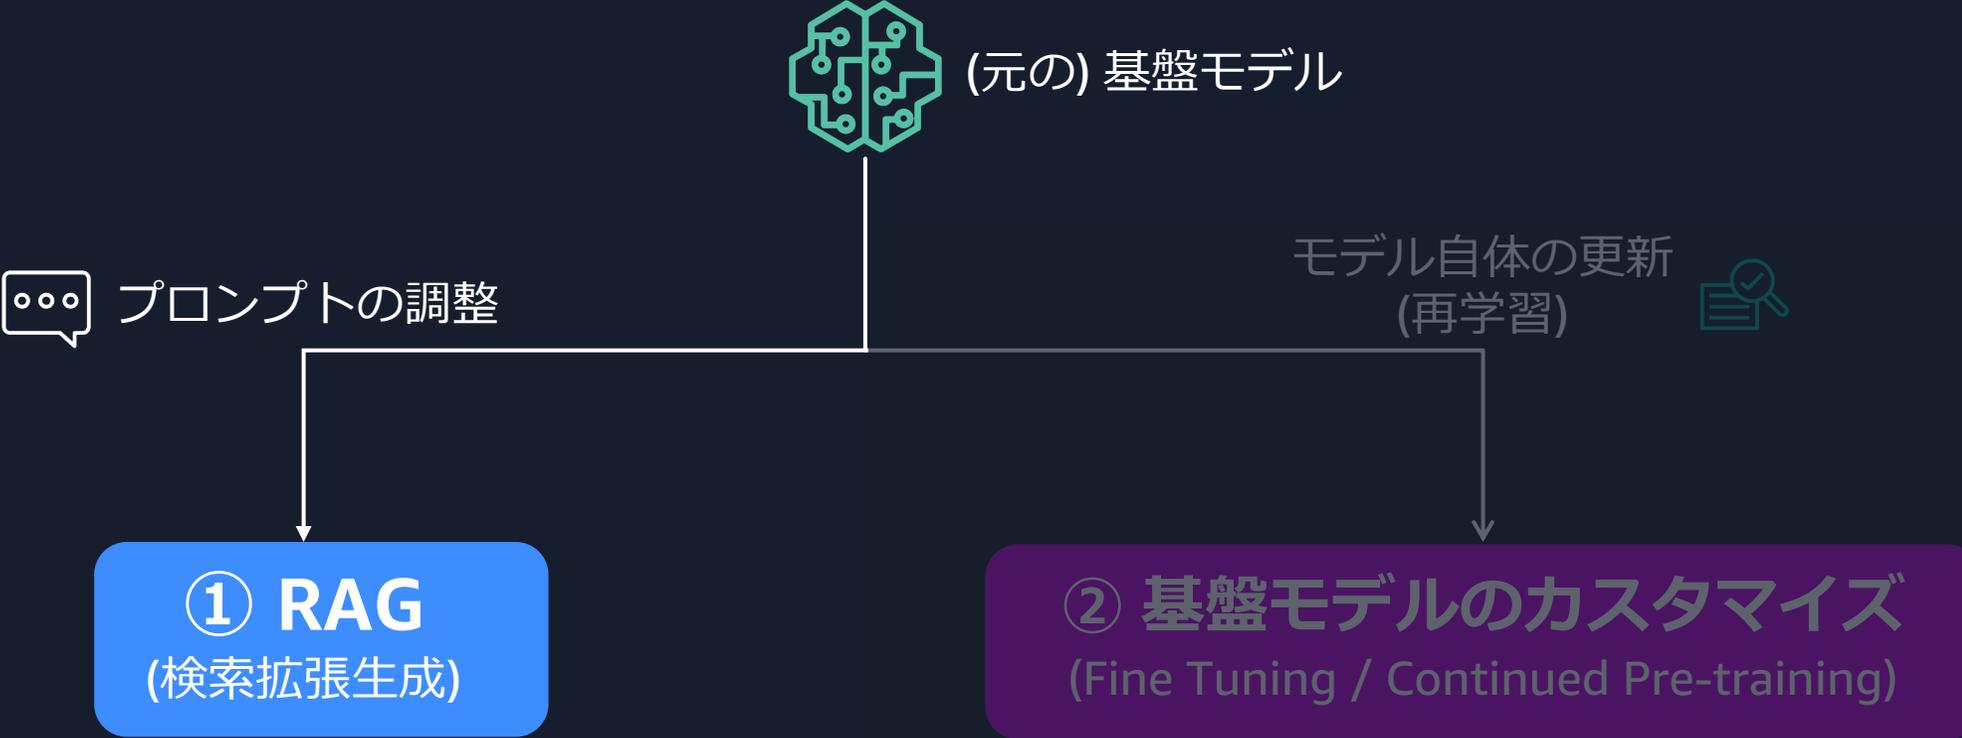
基盤モデルは学習データに含まれていないような情報は回答できない。  
場合によっては不正確な回答をしてしまう（ハルシネーション）。



# 独自データを基盤モデルに活用する方針



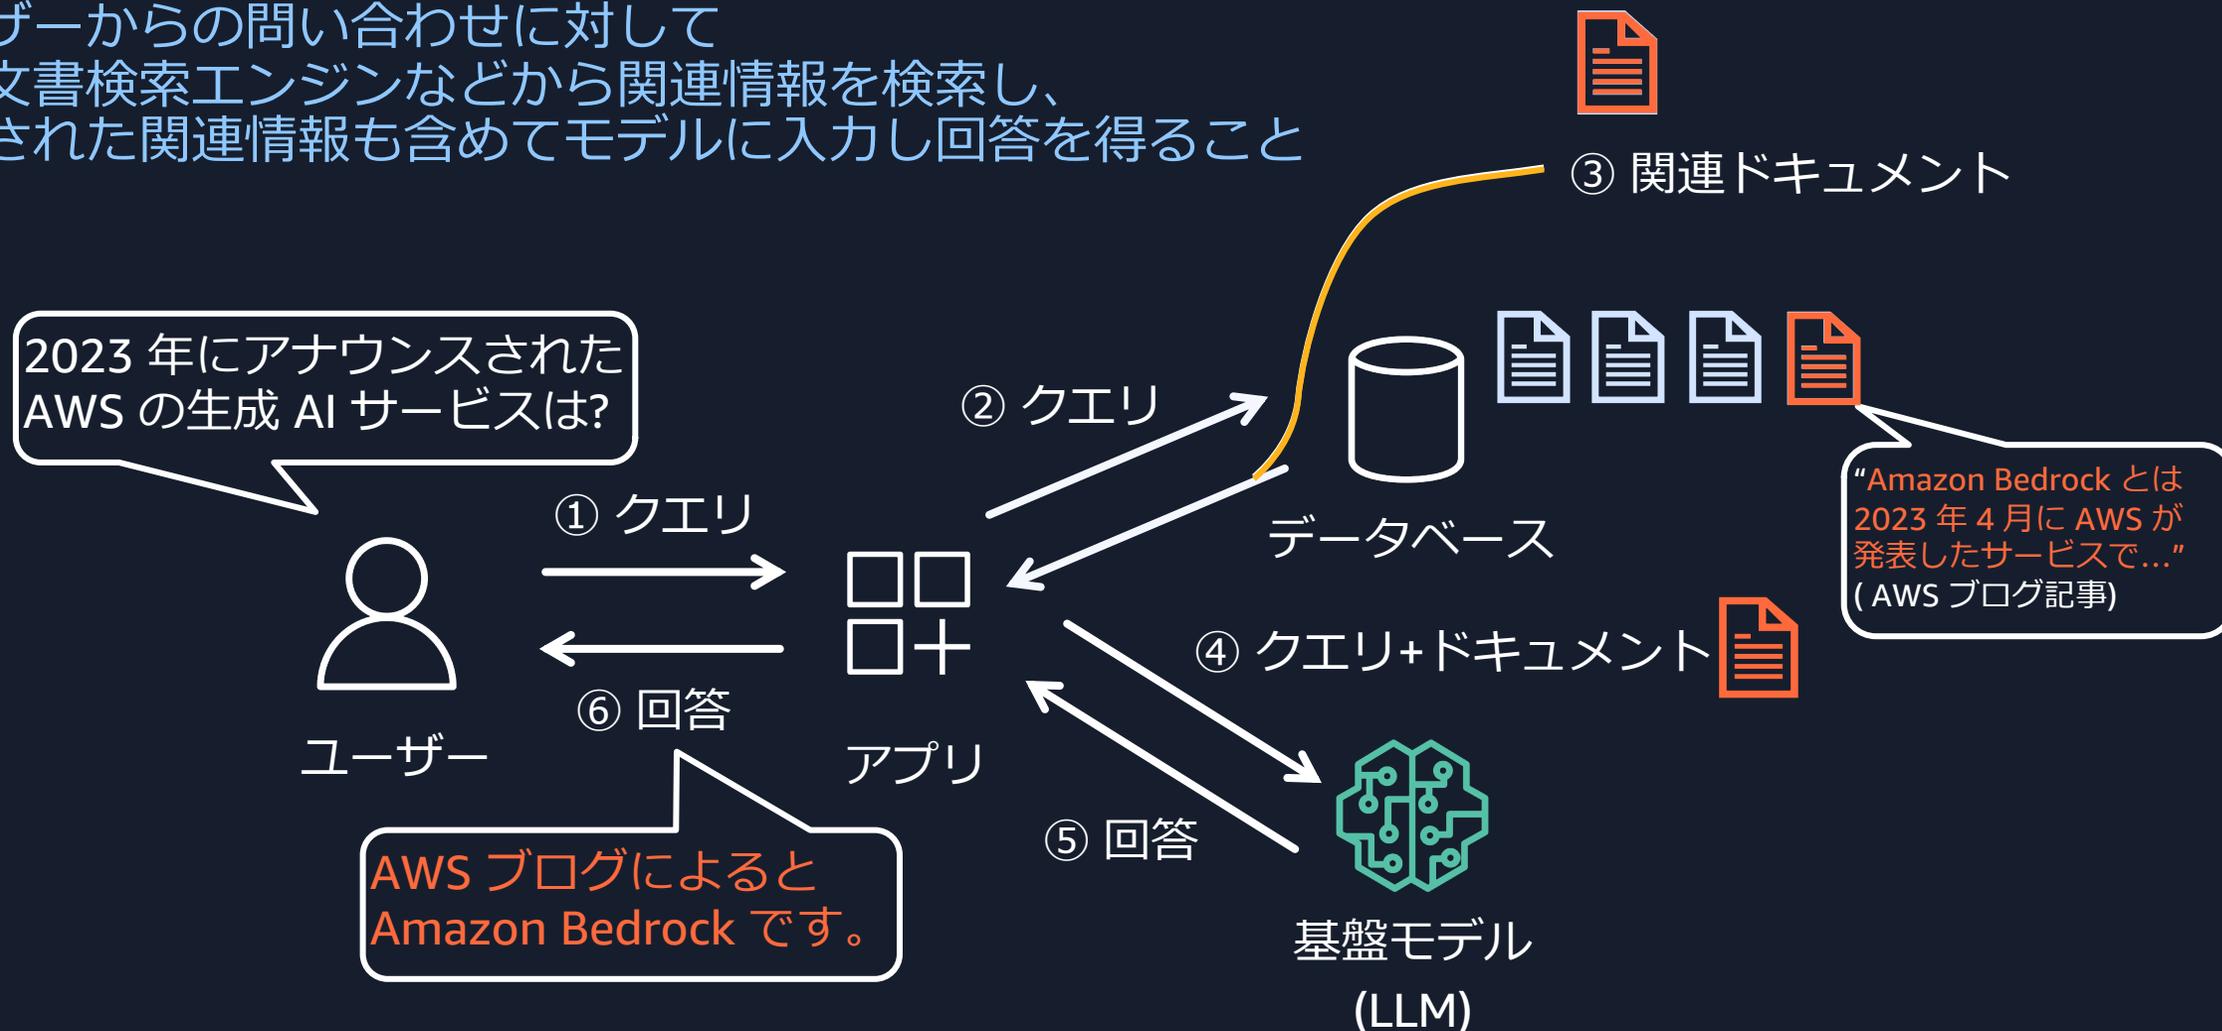
# 独自データを基盤モデルに活用する方針



# ① RAG とは

## Retrieval-Augmented Generation (検索拡張生成)

ユーザーからの問い合わせに対して社内文書検索エンジンなどから関連情報を検索し、取得された関連情報も含めてモデルに入力し回答を得ること



# ① Knowledge Bases for Amazon Bedrock

フルマネージド型の RAG 機能を提供

基盤モデルと自社データソースを組み合わせた RAG (検索拡張生成)をフルマネージドに実現可能に

以下から選択

- Amazon OpenSearch Serverless
- Pinecone
- Redis Enterprise Cloud
- Amazon Aurora
- MongoDB Atlas



ベクトル DB

ベクトル化



Amazon S3



ドキュメント

関連ドキュメント  
を取得

クエリ +  
関連ドキュメント

回答

Amazon Bedrock

LLM  
(Amazon Bedrock 内)



クエリ

回答

ユーザー

一連のフローをフルマネージドで提供



2023年にアナウンスされた AWS の生成系 AI サービスは?



2023年にアナウンスされたAWSの生成系AIサービスはAmazon Bedrockです。[1]

[Show result details >](#)



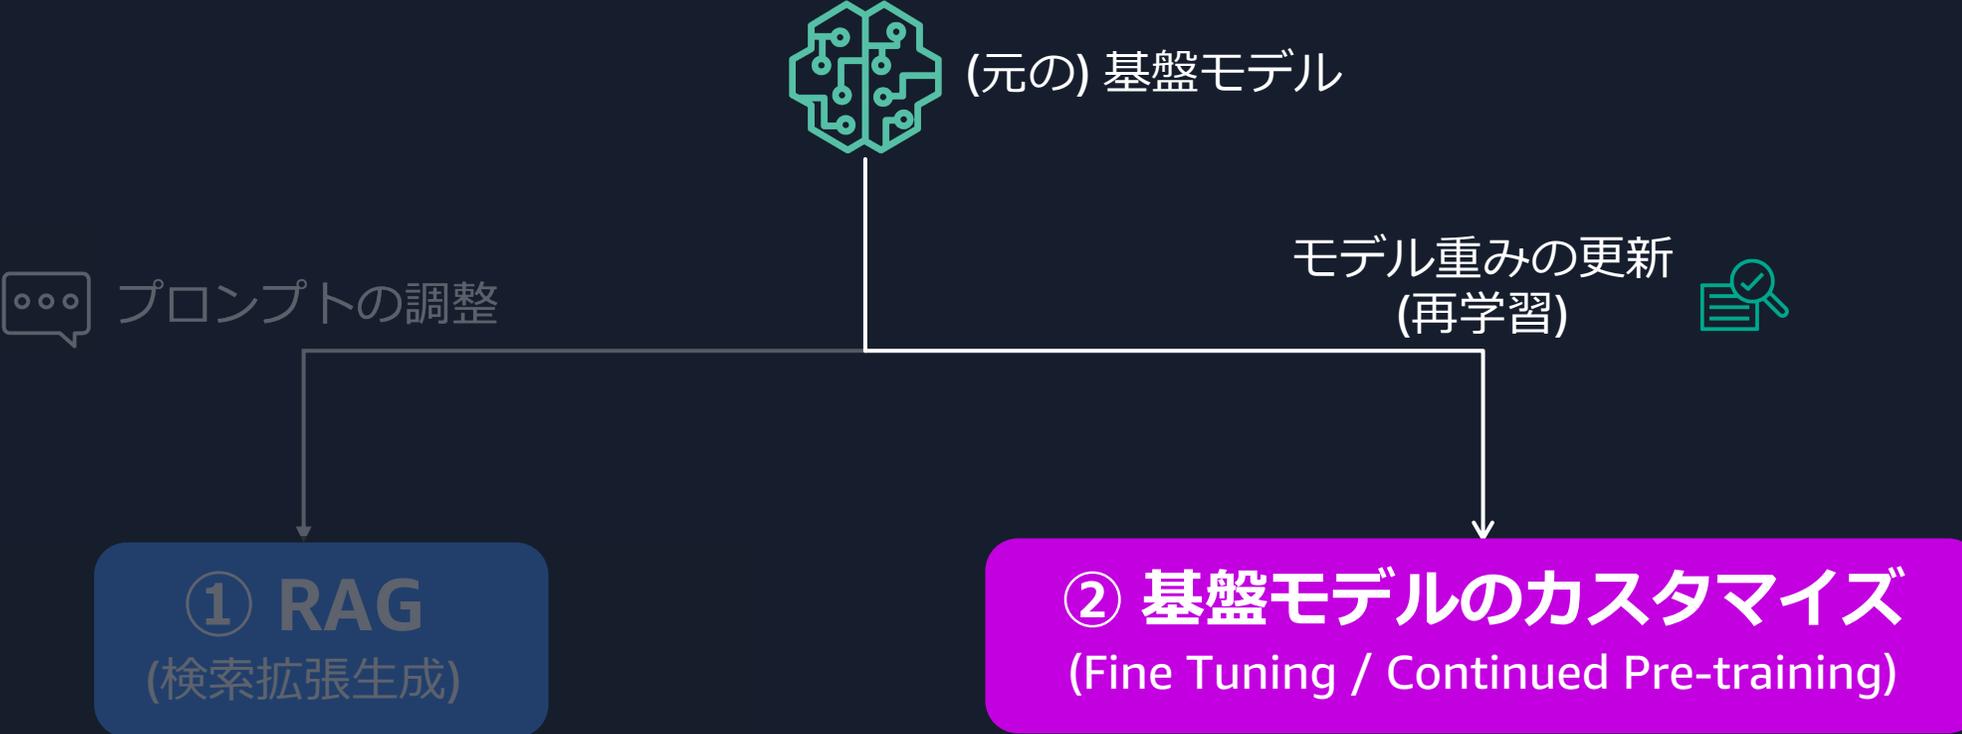
Amazon Bedrockのメリットは何ですか?



Amazon Bedrockのメリットとして、主要な基盤モデルの選択ができること、データを使用してモデルを簡単にカスタマイズできること、APIを動的に呼び出してタスクを実行するフルマネージド型エージェントが構築できること、RAGのネイティブサポートによりFMの機能を拡張できること、データセキュリティとコンプライアンス認証があることが挙げられています。[1]

[Show result details >](#)

# 独自データを基盤モデルに活用する方針



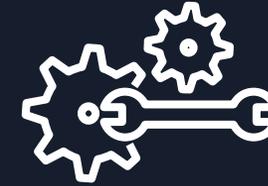
## ② 基盤モデルのカスタマイズ

自身のデータセットを学習して基盤モデル自体をカスタマイズする機能



### Fine Tuning

ラベル付きデータを新たに学習して特定のタスクの精度を高める手法



### Continued Pre-training

大量のラベル無しデータを用いてモデルに新たなドメイン知識を習得させる手法



再学習用のコード不要でマネージドな環境でモデルのカスタマイズを実行

# Custom Model Import for Amazon Bedrock

Amazon Bedrock とは他の環境でトレーニングされたカスタムモデルを Amazon Bedrock にインポートすることが可能に

Amazon SageMaker やローカル環境のような別の環境で学習された基盤モデルをインポートし Amazon Bedrock の既存モデルと同様の API 呼び出しで推論が実行可能に

On-demand 方式で API 呼び出し可能

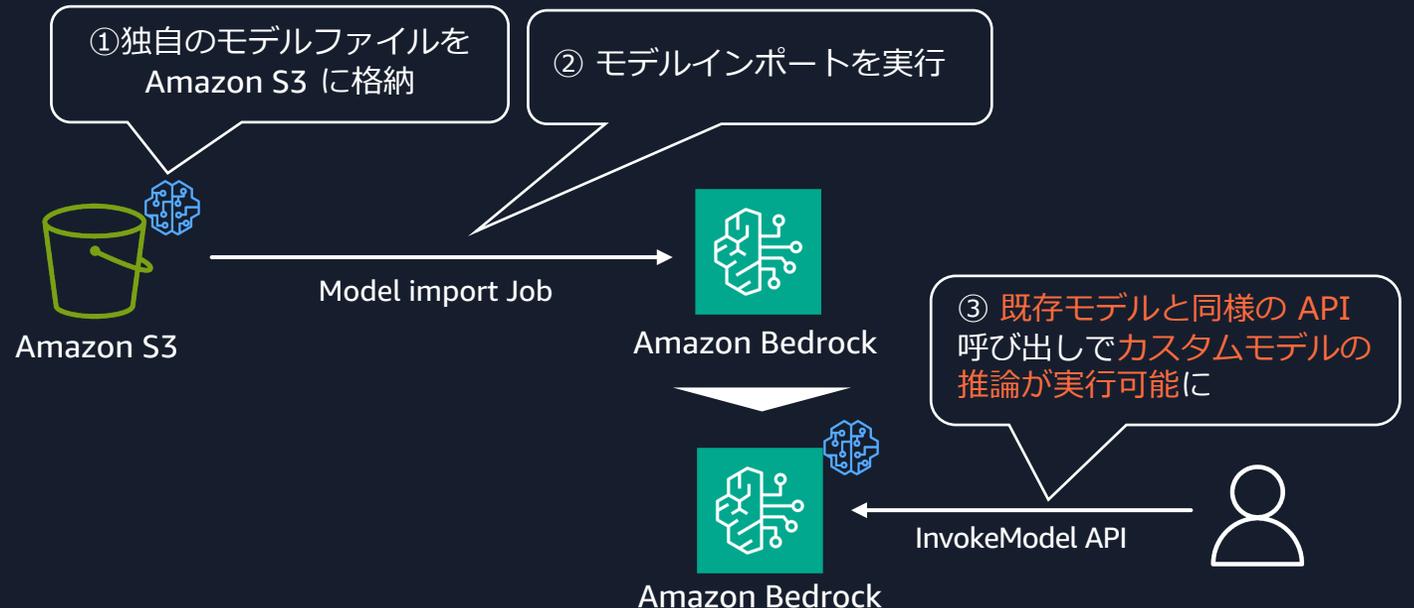
以下のアーキテクチャに対応 (2024 年 6 月時点)

- Mistral
- Flan
- Llama 2 & Llama 3

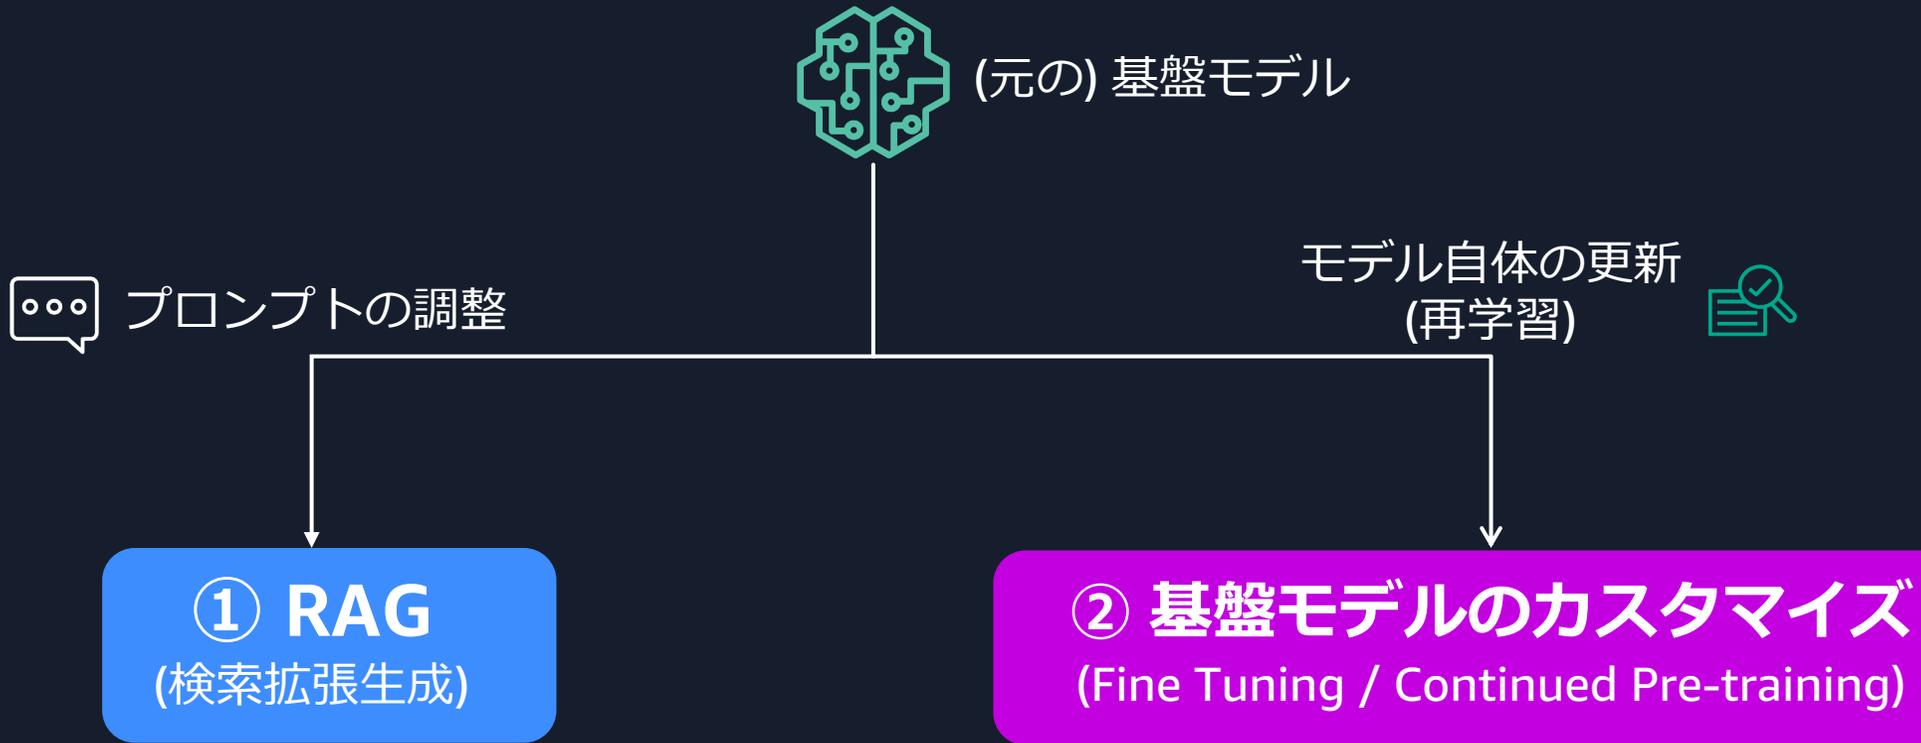
▼ 基盤モデル

- ベースモデル
- カスタムモデル

[Imported models Preview](#)



# 独自データを基盤モデルに活用する方針



## 使い分け (例)

- 最新情報を出力に反映させたい場合
- プロンプト内で与えられた知識のみで十分対応可能な場合
- 未知のドメイン知識の追加や出カスタイルの制御など、モデルの振る舞いをカスタマイズしたい場合

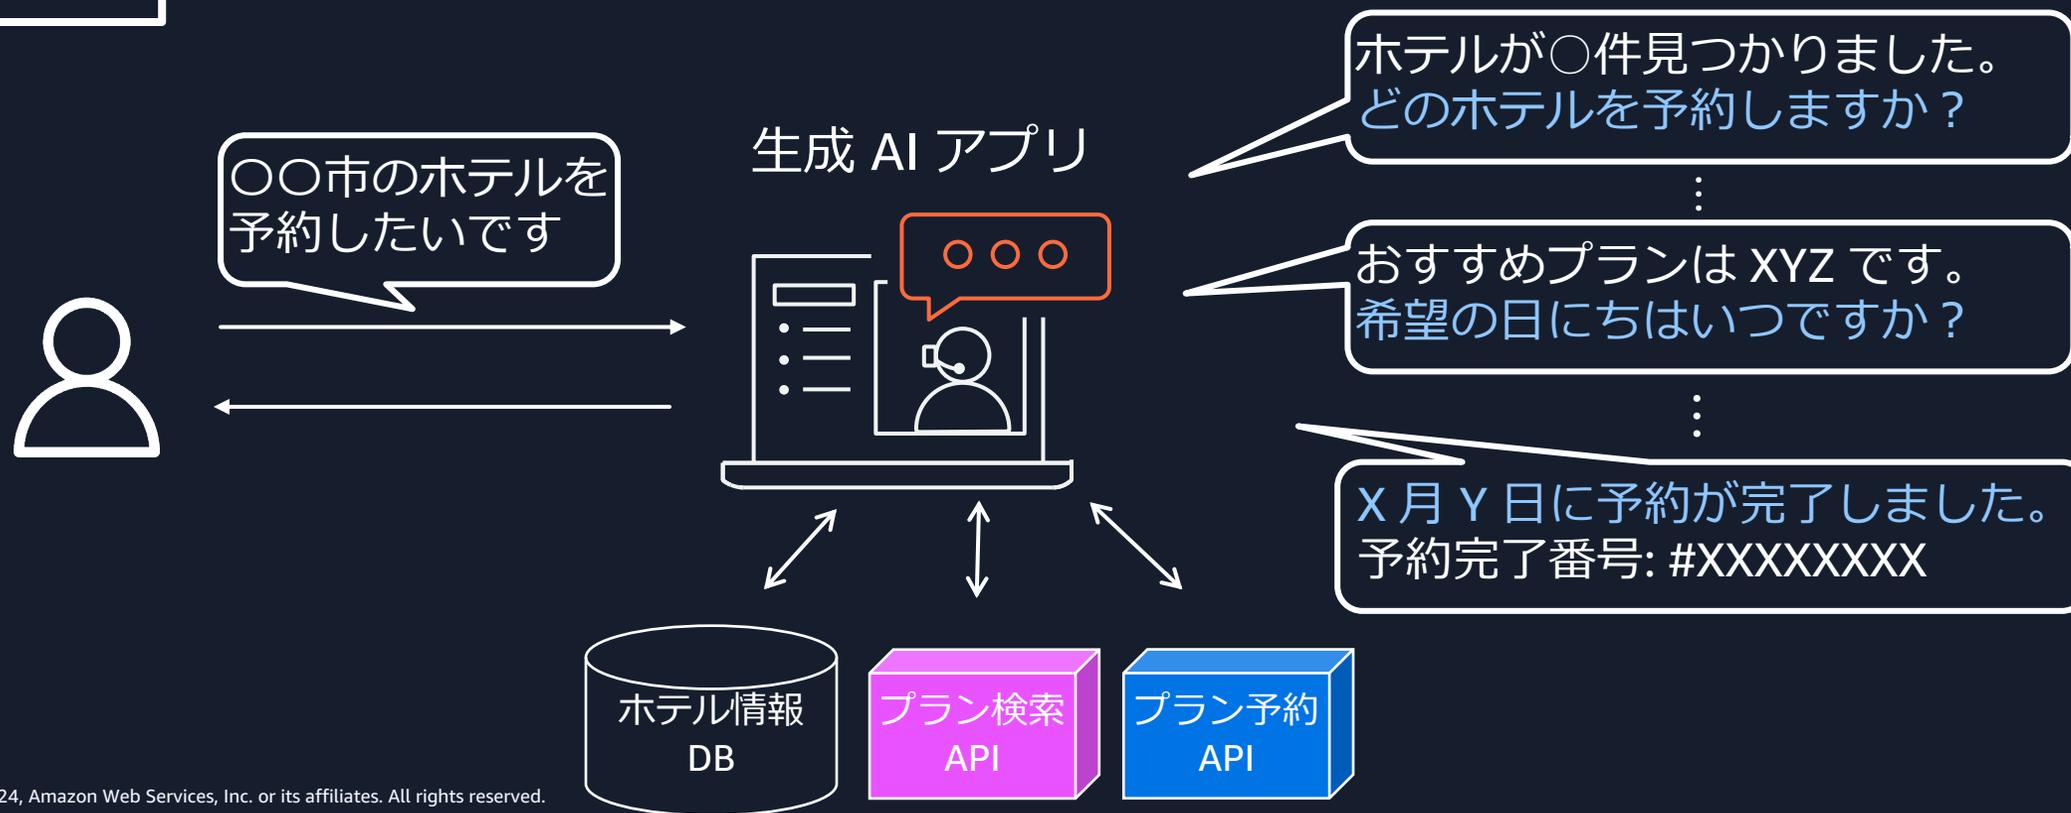
# 生成 AI アプリ開発でよくある課題

- 課題 1 : 独自データの活用
- 課題 2 : データや外部 API との連携の実現
- 課題 3 : 基盤モデルの評価と最適なモデルの選択
- 課題 4 : 生成 AI アプリの適切な利用状況の維持と安定的稼働
- 課題 5 : 生成 AI 活用のアイデアの迅速な実験と評価

# よくある課題 2 : データや外部 API との連携の実現

基盤モデル単体では外部との連携が必要なタスクの実行は難しい。  
自身のデータソースの活用や外部 API 連携と組み合わせてタスクの完了までを実現したい。

## 実現イメージ



# Agent とは？

ユーザーの入力を複数の小さなタスクに分割し、  
タスクごとに適切な API を呼び出すことで回答を生成させるアプローチ



ユーザー

〇〇市のホテルを予約したいです。



Agent (LLM)

まずはデータベースから〇〇市のホテルを探そう。  
各ホテルにはおすすめのプランもあるみたいだ。  
これも追加の情報として提示しよう。  
まずはどのホテルに宿泊したいかを確認しないと。

# Agent とは？

ユーザーの入力を複数の小さなタスクに分割し、  
タスクごとに適切な API を呼び出すことで回答を生成させるアプローチ



ユーザー

〇〇市のホテルを予約したいです。



Agent (LLM)

〇〇市のホテルは 8 件見つかりました。  
ホテル A は朝食付きプラン、ホテル B は素泊まりプランが  
おすすめです。ホテル C は…

どちらのホテルへのご宿泊を希望されますか？

# Agents for Amazon Bedrock

API を呼び出しタスクを実行する Agent 機能をフルマネージドで提供

基盤モデルを使ってユーザのクエリを理解し、登録された情報を Knowledge Base から検索したり、タスク完了に必要なアクションを実行

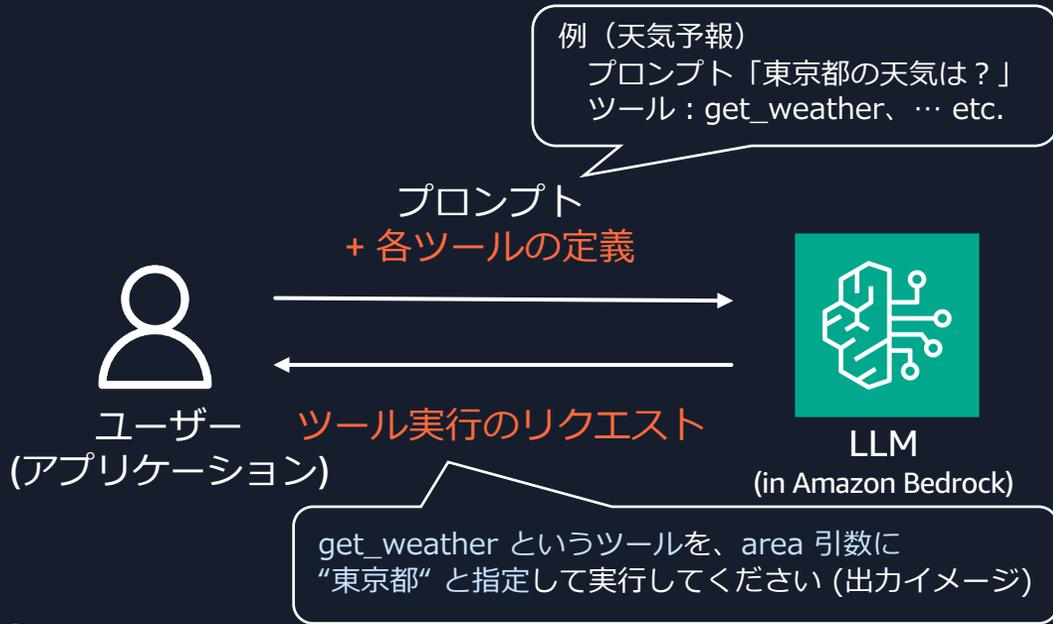


# その他関連実装パターン

## Tool use (Function calling)

外部ツールや関数などを定義し呼び出すことでモデルの能力を拡張する機能

「どのツールをどのような引数で呼ぶべきか」をモデルの出力として返し、ユーザー側 (アプリ側) でツールを実行

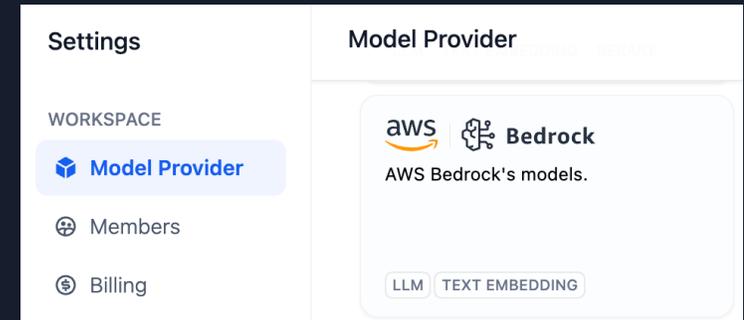


## OSS からの Amazon Bedrock 活用

### Dify

LangGenius 社提供のオープンソースの LLM アプリケーション開発プラットフォーム

Agent 機能、AI ワークフロー構築、RAG パイプラインなどの機能が搭載。モデルプロバイダーとして Amazon Bedrock を利用可能。



### LangChain

LLM アプリケーション開発のためのオープンソースフレームワーク

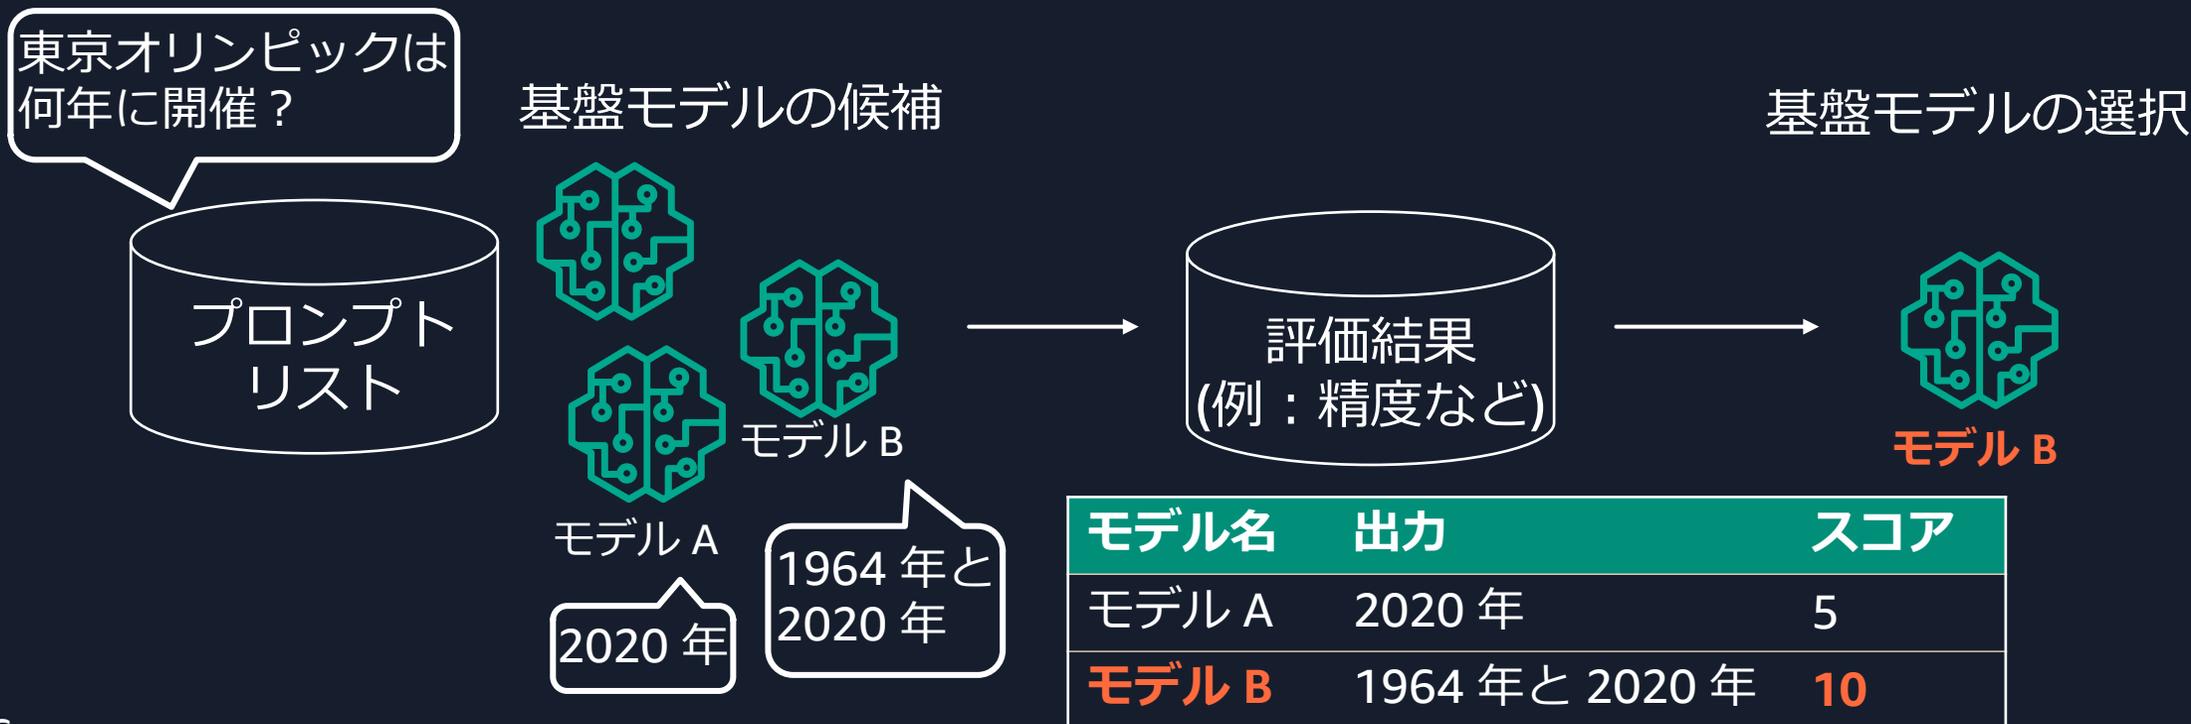
LLM Agent、チャットボット、RAG、リコメンデーションなど様々なアプリケーションのパターンが実装可能となるライブラリ。LLM として Amazon Bedrock を利用可能。

# 生成 AI アプリ開発でよくある課題

- 課題 1 : 独自データの活用
- 課題 2 : データや外部 API との連携の実現
- 課題 3 : 基盤モデルの評価と最適なモデルの選択
- 課題 4 : 生成 AI アプリの適切な利用状況の維持と安定的稼働
- 課題 5 : 生成 AI 活用のアイデアの迅速な実験と評価

# よくある課題 3 : お客様のユースケースに適した基盤モデルの選択の必要性

最適な基盤モデルを選択するためには、ユースケースに沿ったプロンプトを用いて評価の実施および評価プログラムの実装などの工数がかかる。



# Model Evaluation on Amazon Bedrock

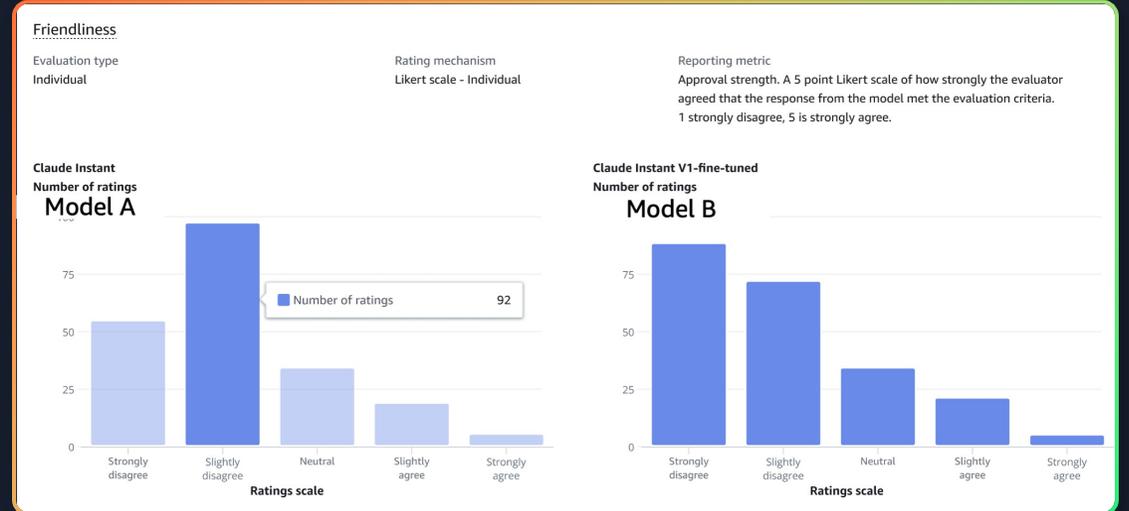
複数の基盤モデルをコード不要で比較・評価し  
ユースケースに最適なモデルを選択可能に

評価方法：  
自動評価 (Automatic Evaluation)、または  
人間による評価 (Human Evaluation)を選択

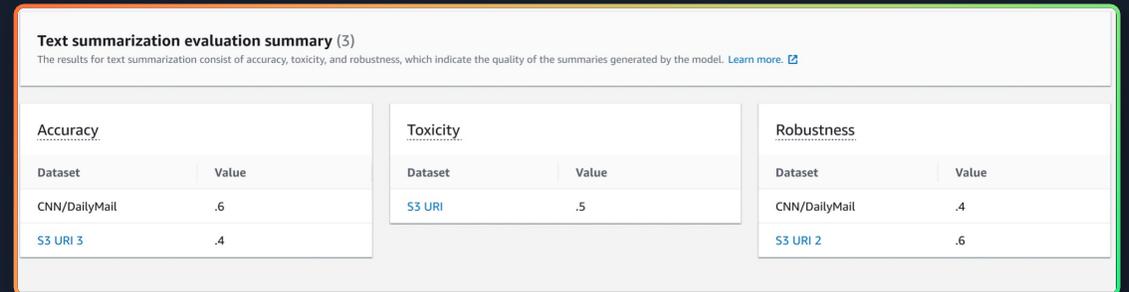
評価用データセット：  
お客様独自のデータセット、または  
ビルトインのデータセットを指定

評価指標：  
事前定義済みの複数の指標や  
お客様独自のカスタム指標も指定可能

## 人間による評価についてのレポート



## 自動評価レポート



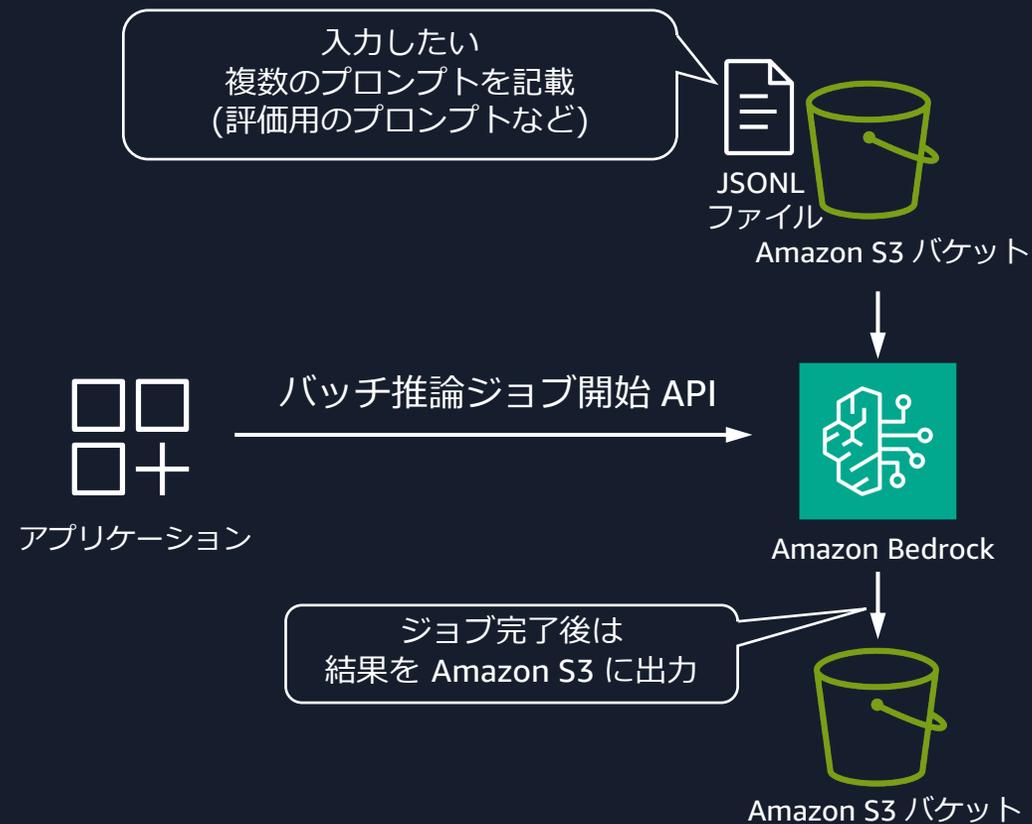
# バッチ推論

複数のプロンプトを非同期にバッチで推論

スロットリングを回避し  
大規模なジョブを確実に処理

その他ユースケース

- 定期的なオフラインでの推論
  - 例：ユーザーごとにパーソナライズされたメール配信の文面作成
- RAG などの用途での埋め込みベクトルの一括作成



# 生成 AI アプリ開発でよくある課題

- 課題 1 : 独自データの活用
- 課題 2 : データや外部 API との連携の実現
- 課題 3 : 基盤モデルの評価と最適なモデルの選択
- 課題 4 : 生成 AI アプリの適切な利用状況の維持と安定的稼働
- 課題 5 : 生成 AI 活用のアイデアの迅速な実験と評価

# よくある課題 4 : 生成 AI アプリの適切な利用状況の維持と安定的稼働

生成 AI の不適切な利用や有害な結果の出力を避けられているか、  
ユーザーのリクエストに安定的に応えられているか、管理し維持する必要がある。



## スケーリング

リクエスト



## プロンプトのモニタリング



- ・ ログ管理・分析
- ・ 精度評価

# Guardrails for Amazon Bedrock

基盤モデルの不適切な入出力をブロックし、責任ある AI ポリシーの実現

自社ポリシーに従って、ユーザーの入力や基盤モデルの出力から望ましくないコンテンツを制御するためのガードレールを定義

- 拒否トピック
- コンテンツフィルタ
- PII リダクション
- ワードフィルタ

基盤モデルがネイティブで提供する保護機能より 85% 多くの有害コンテンツをブロック

ファインチューニングされたモデルや Agents / Knowledge Bases for Amazon Bedrock に対しても適用可能

The screenshot displays the Amazon Bedrock Guardrails configuration interface for a 'Working draft: antje-banking-assistant'. The interface is divided into several sections:

- Denied topics (1):** A table with one entry: 'Investment advice' with instructions: 'Investment advice refers to guidance or recommendations provided by a financial professional, adv...'. The 'Investment advice' text is highlighted with a red box.
- Content moderation: filter strengths:** A table with two columns: 'Prompt filters' and 'Response filters'. Both columns have 'ON' for 'Toxicity filter strength' and 'High' for 'Insults filter strength', 'Sexual filter strength', and 'Violence filter strength'.
- Default responses:** A table with two columns: 'Blocked prompts' and 'Blocked responses'. Both columns have the text: 'Sorry, I can't comment on that.'

On the right side, the 'Test' panel shows a 'Working draft' dropdown, the 'Claude Instant v1.2' model, and a 'Prompt' input field containing 'Should I open a credit card account?'. Below the prompt, the 'Model response' and 'Final response' sections show a warning message: 'Here are a few things to consider when deciding whether to open a credit card account: - Having a credit card and using it responsibly can help you establish credit history. This is important for things like qualifying for loans in the future. However, be sure you can pay the bill in full each month to avoid interest charges.' At the bottom of the test panel, a 'Guardrail check' section shows a green checkmark and the text 'Passed View trace >', with a red arrow pointing to it. A 'Run' button is also visible.

# 実行履歴の記録: Model Invocation Logging

基盤モデルの入出力結果をログとして記録

```
"timestamp": "2024-01-14T15:46:05Z",
"modelId": "anthropic.claude-v2:1",
"input": {
  "inputContentType": "application/json",
  "inputBodyJson": {
    "prompt": "\n\nHuman: 日本で二番目に高い山は何ですか?\n\nAssistant:",
    "max_tokens_to_sample": 300,
    "temperature": 1,
    "top_k": 250,
    "top_p": 0.999,
    "stop_sequences": [
      "\n\nHuman:"
    ],
    "anthropic_version": "bedrock-2023-05-31"
  },
  "inputTokenCount": 26
},
"output": {
  "outputContentType": "application/json",
  "outputBodyJson": [
    {
      "completion": " ",
      "stop_reason": null,
      "stop": null
    },
    {
      "completion": "日本で2番目に高い",
      "stop_reason": null,
      "stop": null
    },
    {
      "completion": "山は北岳です.\n\n",
      "stop_reason": null,
      "stop": null
    }
  ]
}
```

実行時刻

基盤モデルの種類

入力プロンプト

入力パラメータ

出力結果

- デフォルトでは AWS CloudTrail によって API 実行時刻と基盤モデルの種類が記録される



- Model Invocation Logging を有効化することで基盤モデルの入出力内容や入力パラメータ設定値も含めた実行履歴を記録することが可能に
- ログの保存先には Amazon S3 や Amazon CloudWatch を指定

# Provisioned Throughput

スループットを確保し安定した API 実行が可能に

通常的方式（オンデマンド方式）の場合、  
1 分間当たりのリクエスト数およびトークン数  
に上限がある

→ モデルユニット（1 分間に処理可能な入出力  
トークン数に基づく処理単位）を購入し  
一定のスループットを確保

トラフィックの急増に対応し、  
一貫したユーザー体験を確保

コミット期間なし or コミット期間付き  
(1 ヶ月または 6 ヶ月) での購入

Amazon Bedrock > Provisioned throughput > Purchase provisioned throughput

## Purchase provisioned throughput [info](#)

**Provisioned throughput details [info](#)**

Provisioned throughput name  
  
Name can have up to 40 characters, and it must be unique. Valid characters A-Z, a-z, 0-9, and - (hyphen).

Select model

▶ Tags - optional

**Model units & commitment term [info](#)**  
Select model units & commitment term to purchase Provisioned throughput. To estimate cost use [MU Estimator](#).

Model units  
Please request the model units here before purchasing provisioned throughput. [AWS support center](#)

Select commitment term  
Commitment terms locks the purchase for the selected duration.

**Estimated purchase summary**  
To view the provisioned throughput pricing please visit [Pricing information](#)

Estimated hourly cost	Estimated daily cost	Estimated monthly cost
-	-	-

**Edits to model and model units will be restricted** [Learn more](#)

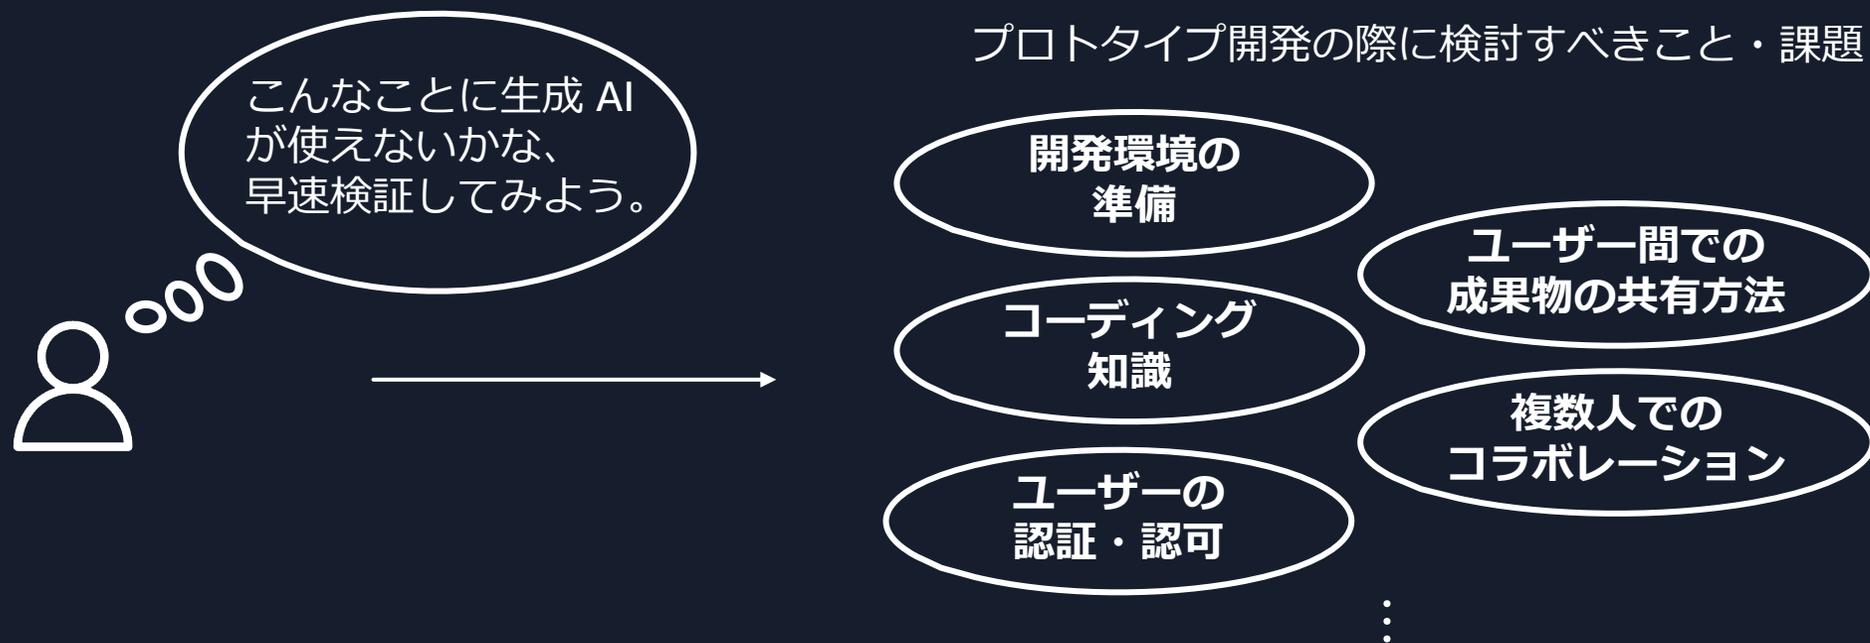
Once provisioned throughput is purchased, model units cannot be updated and the model can only be updated to another model with the same lineage.

# 生成 AI アプリ開発でよくある課題

- 課題 1 : 独自データの活用
- 課題 2 : データや外部 API との連携の実現
- 課題 3 : 基盤モデルの評価と最適なモデルの選択
- 課題 4 : 生成 AI アプリの適切な利用状況の維持と安定的稼働
- 課題 5 : 生成 AI 活用のアイデアの迅速な実験と評価

# よくある課題 5 : 生成 AI 活用のアイデアの迅速な実験と評価

生成 AI ユースケースのアイデアの検証や評価のスピードを加速したい。  
その際、コーディングや認証認可など、本来検証したい生成 AI 以外の部分が  
アイデア検証のスピードを妨げる。



# Amazon Bedrock Studio

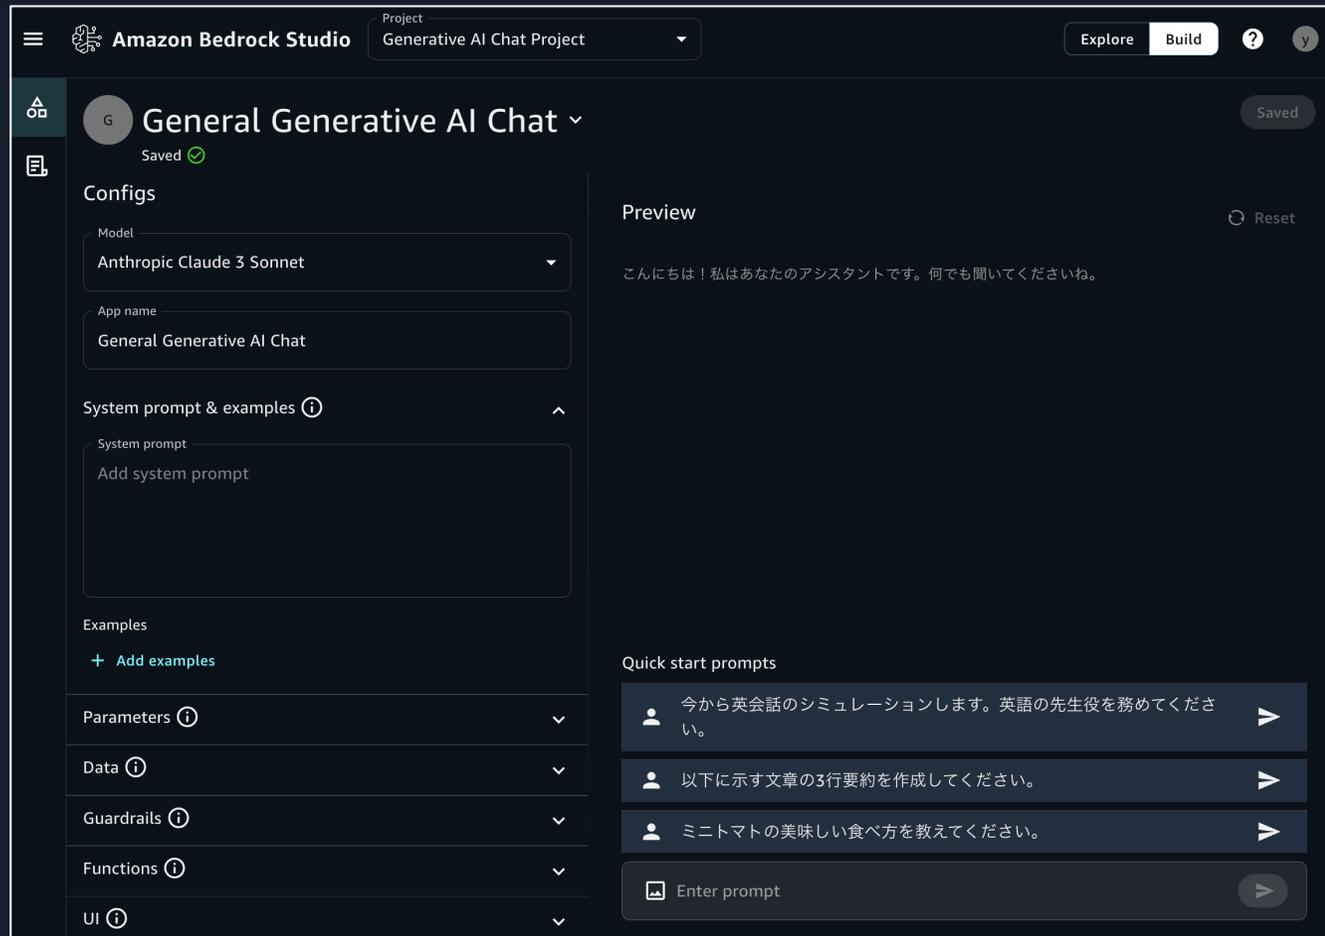
生成 AI アプリをコード不要で簡単にプロトタイプ化でき  
組織内で共有できる SSO 対応 Web アプリケーション

Amazon Bedrock の各種機能を活用した  
生成 AI アプリケーションのプロトタイプ開発

- 複数の基盤モデルの選択・呼び出し
- ナレッジベース
- エージェント (Function)
- ガードレール

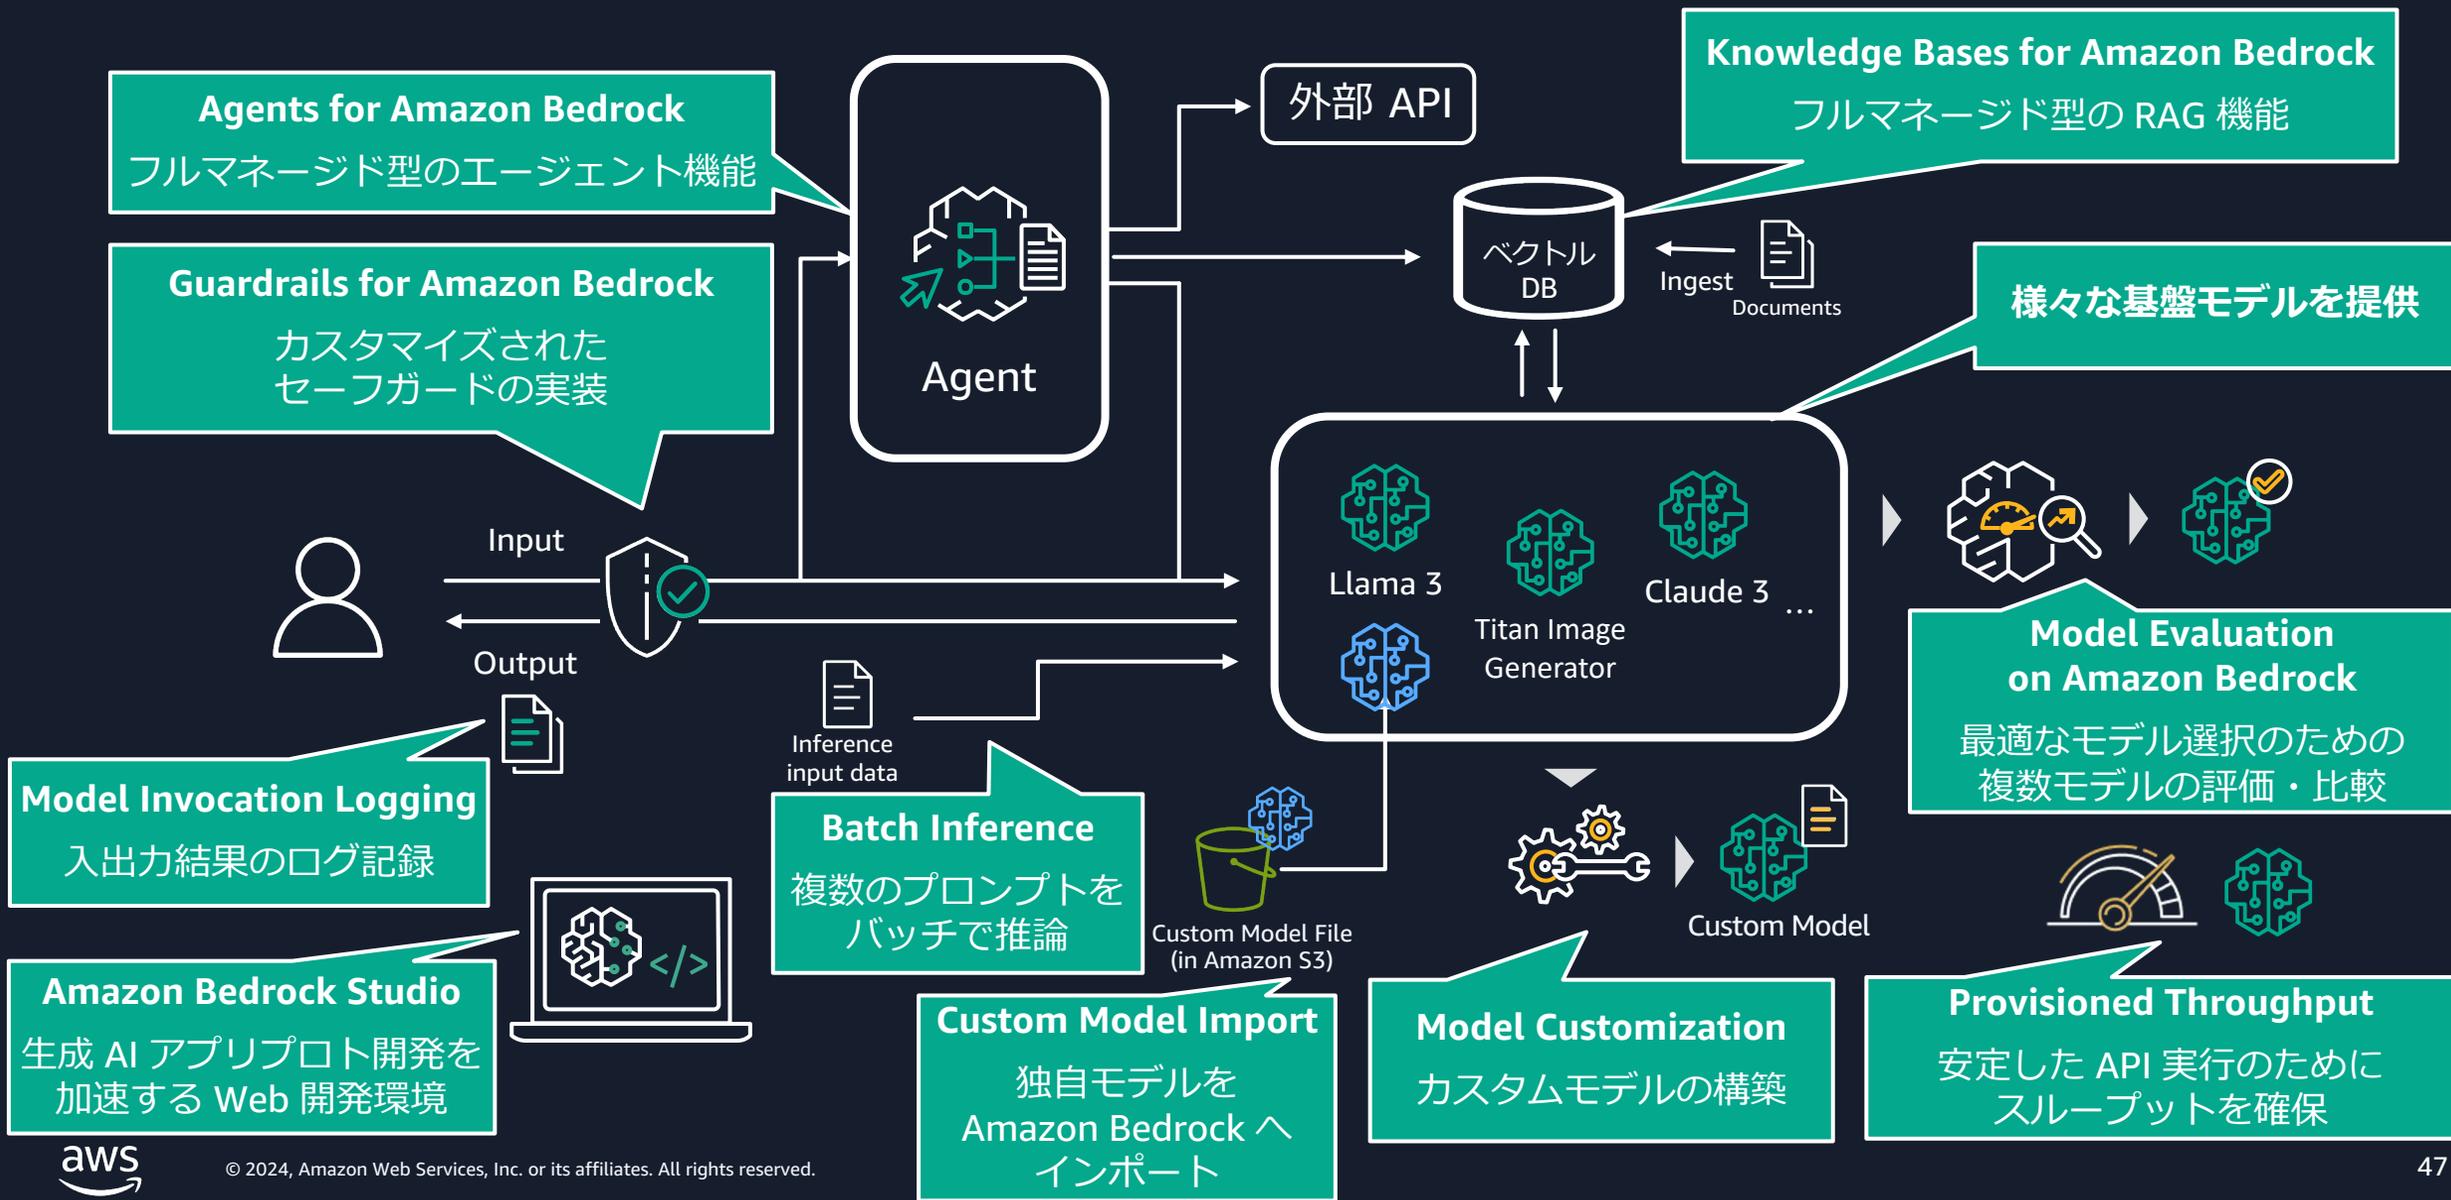
SSO でのログイン  
(AWS IAM Identity Center)

作成したプロトタイプアプリケーションを  
組織間で簡単に共有



# (再掲) Amazon Bedrock の主な機能の全体像

2024年6月 ver.



# まとめ

- Amazon Bedrock は基盤モデルを活用した生成 AI アプリケーションを簡単に構築可能なマネージドサービス
- 様々な基盤モデルをユースケースに応じて選択し API を通じて利用可能
- 生成 AI アプリケーションの開発・運用をサポートする様々な機能を提供
  - RAG (検索拡張生成)
  - Fine Tuning / Continued Pre-training
  - Custom Model Import
  - エージェント
  - 基盤モデル評価
  - ガードレール
  - Amazon Bedrock Studio
  - ... etc.

# AWS Black Belt Online Seminar とは

- 「サービス別」「ソリューション別」「業種別」などのテーマに分け、アマゾン ウェブ サービス ジャパン合同会社が提供するオンラインセミナーシリーズです
- AWS の技術担当者が、AWS の各サービスやソリューションについてテーマごとに動画を公開します
- 以下の URL より、過去のセミナー含めた資料などをダウンロードすることができます
  - <https://aws.amazon.com/jp/aws-jp-introduction/aws-jp-webinar-service-cut/>
  - <https://www.youtube.com/playlist?list=PLzWGOASvSx6FIwIC2X1nObr1KcMCBBlqY>



ご感想は X (Twitter) へ！ハッシュタグは以下をご利用ください  
#awsblackbelt

# Thank you!

