AWS で簡単に作る生成系 AI モデル

デモンストレーション

伊藤 芳幸　Yoshiyuki Ito

機械学習ソリューションアーキテクト

自己紹介

伊藤 芳幸（いとう よしゆき）

機械学習ソリューションアーキテクト

- AWS の AI/ML を活用してビジネス価値を創出するお客様にアーキテクティング面の技術支援を提供
- SIer でエンジニアとコンサルタント、事業会社でデータストラテジストを経験

好きな AWS サービス

Amazon SageMaker

基盤モデルを活用する3通りの方法

再掲

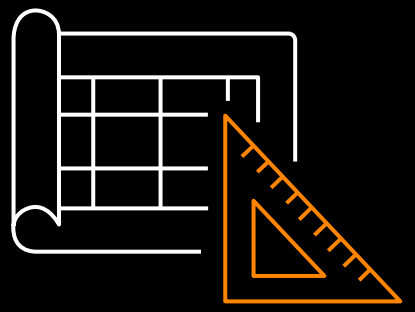

自ら基盤モデルを
スクラッチ開発

コスト、開発期間要
業務・ML専門性必須

モデルプロバイダー

公開済み基盤モデルの
活用・チューニング

運用に辿り着くまでに
相当な分類作業要

モデルチューナー

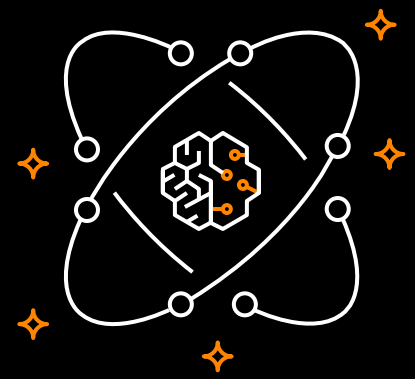

生成系AI、API、基盤モデル
提供ベンダの活用

データ管理・コスト管理要
自社カスタマイズ余地小

モデルコンシューマー

このセッションで得られること

生成系 AI の活用アイディアとシステムとして考慮すべき点を知る

このセッションでやること

- 様々な公開済み基盤モデルを簡単に試す
- GUIからワンクリックで AWS 環境に 生成系 AI モデルをデプロイする
- 生成系 AI を活用したアプリケーションの紹介
  - 社内ドキュメントからの回答文生成
  - コールセンターでの通話要約文生成 **（日本語）**
- 開発者向けコード生成ソリューションの紹介

このセッションではやらないこと

- Amazon Bedrock のデモ
- Amazon Titan のデモ

アジェンダ

- 様々な公開済み基盤モデルを簡単に試す
- GUI からワンクリックで AWS 環境に 生成系 AI モデルをデプロイする
- 生成系 AI を活用したアプリケーションの紹介
  - 社内ドキュメントからの回答文生成
  - コールセンターでの通話要約文生成
- 開発者向けコード生成ソリューションの紹介

アジェンダ

- 様々な公開済み基盤モデルを簡単に試す
- GUI からワンクリックで AWS 環境に 生成系 AI モデルをデプロイする
- 生成系 AI を活用したアプリケーションの紹介
  - 社内ドキュメントからの回答文生成
  - コールセンターでの通話要約文生成
- 開発者向けコード生成ソリューションの紹介

Amazon SageMaker JumpStart

既存の基盤モデルにアクセスして開発・運用を始める

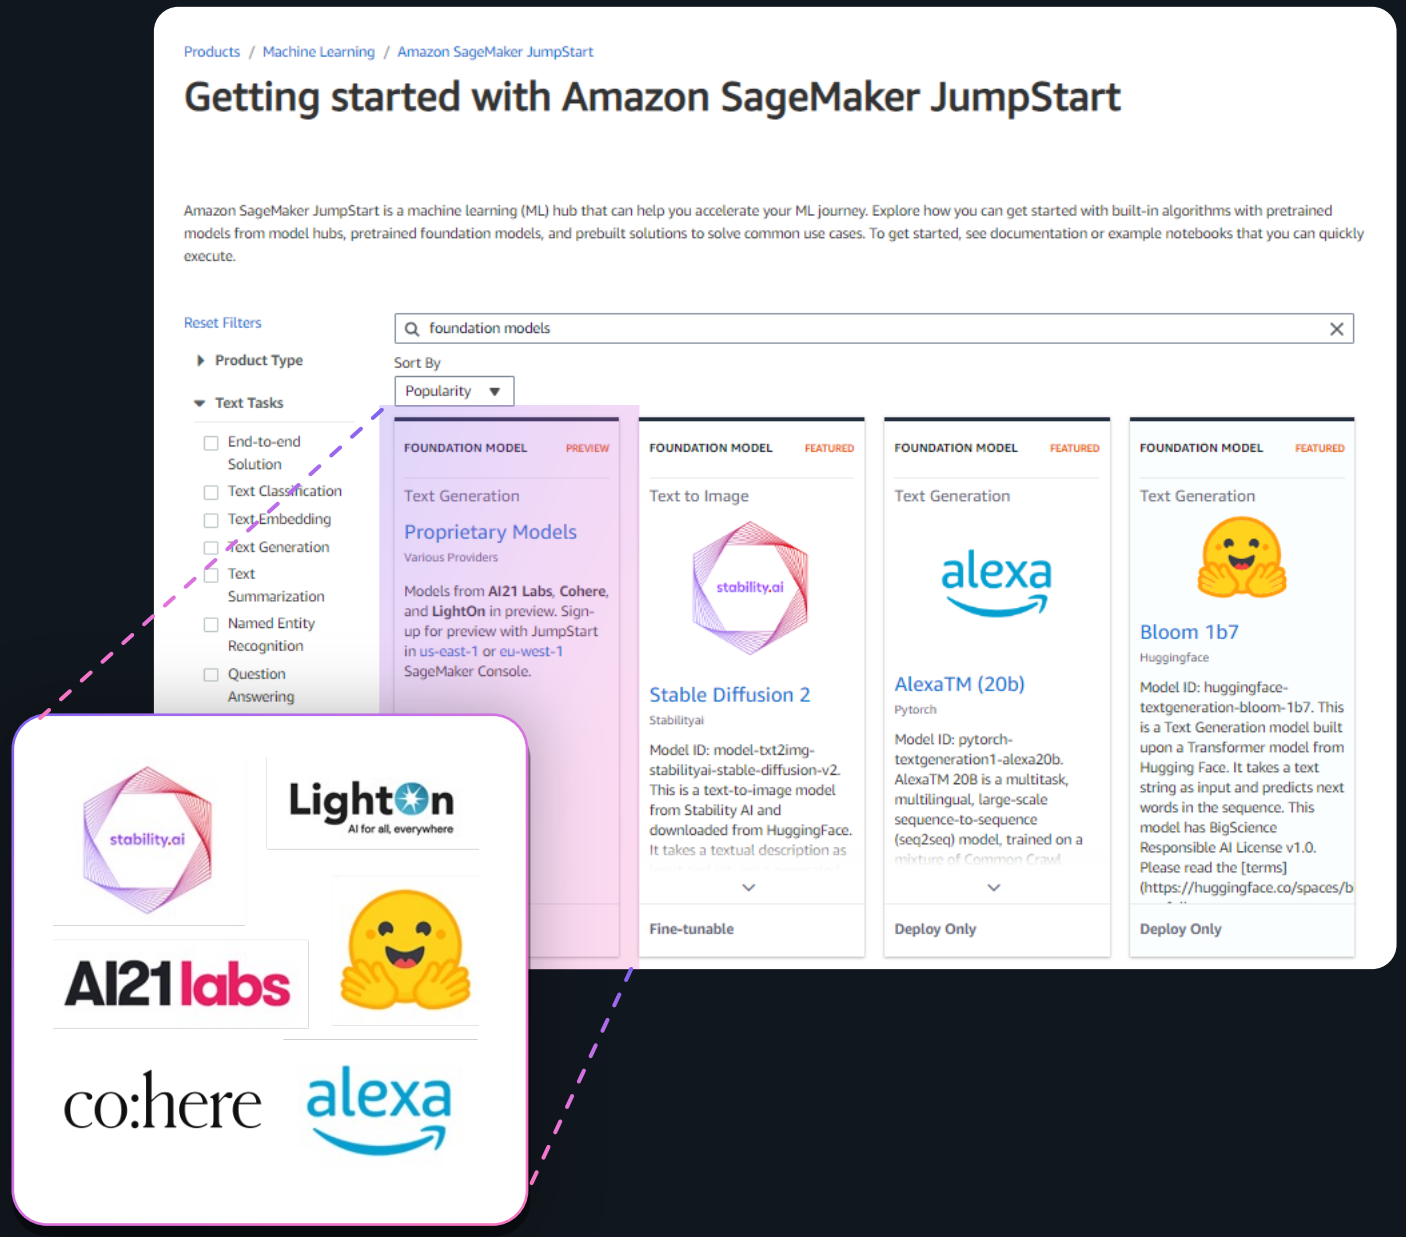

SageMaker JumpStart: 基盤モデルを利用する 3 つの方法

SageMaker コンソール (プレビュー)

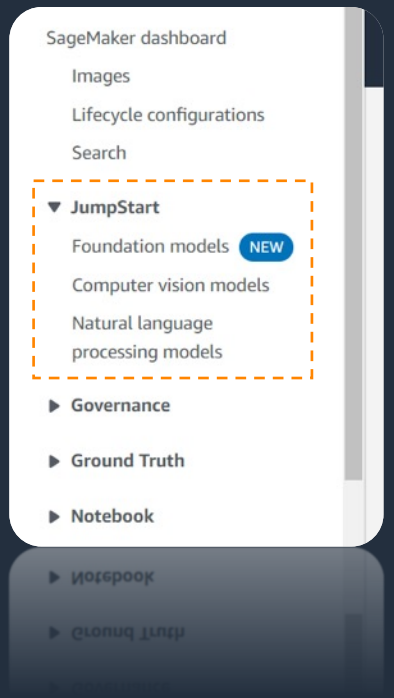

SageMaker ノートブック

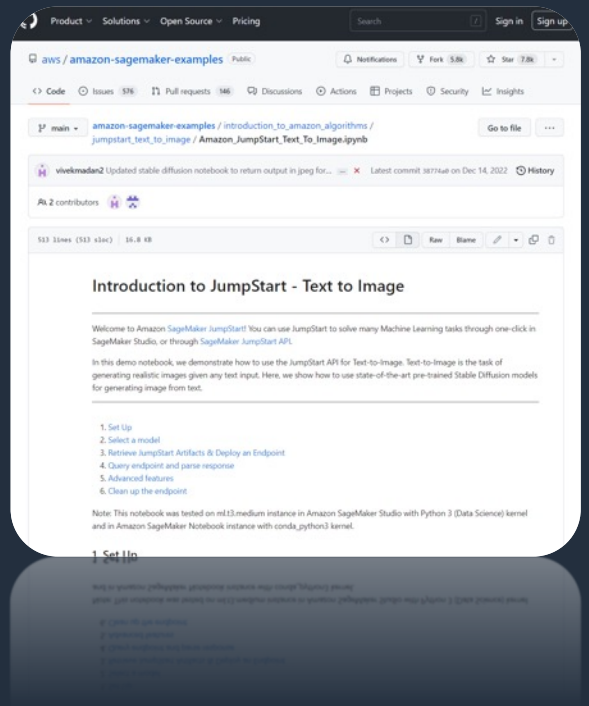

SageMaker Studio
ワンクリックデプロイ

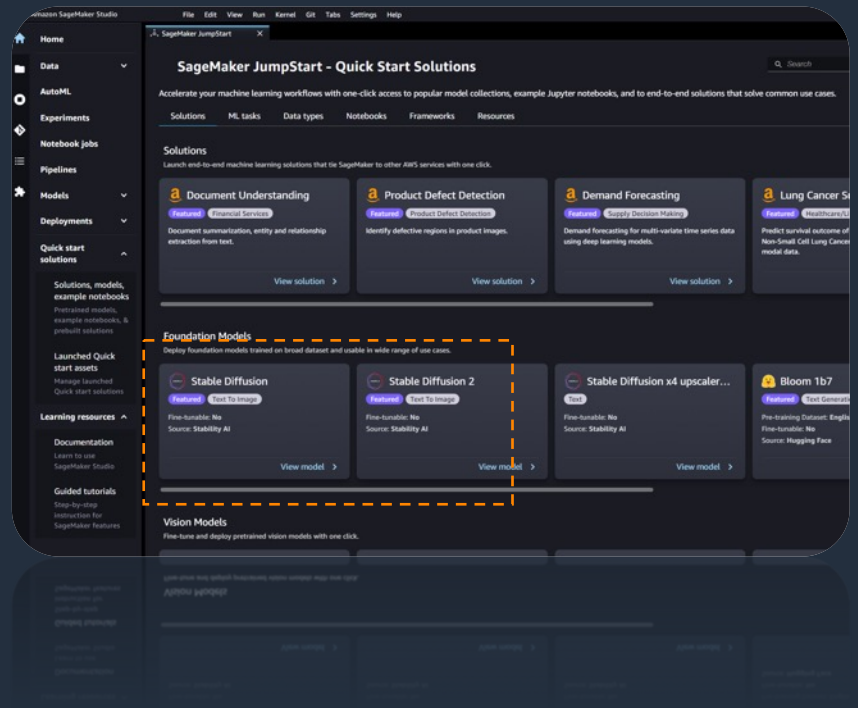

SageMaker JumpStart: 基盤モデルを利用する 3 つの方法

SageMaker コンソール (プレビュー)

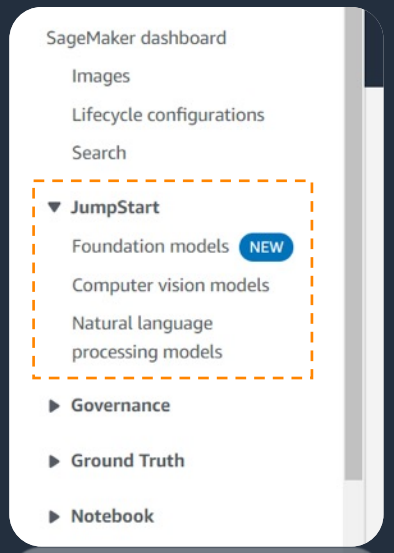

SageMaker ノートブック

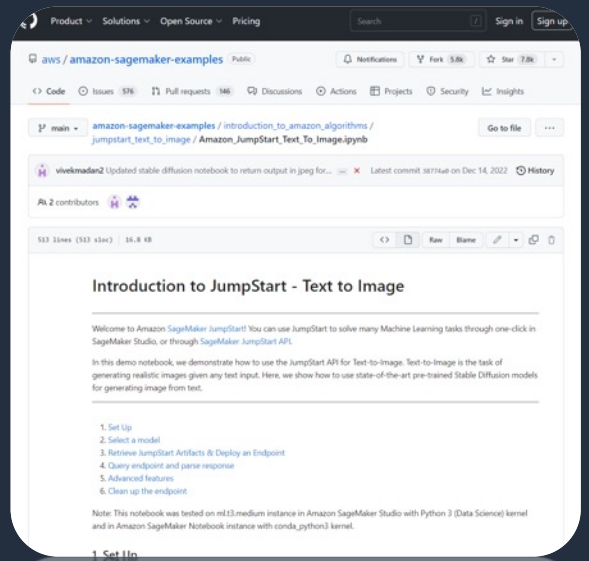

SageMaker Studio
ワンクリックデプロイ

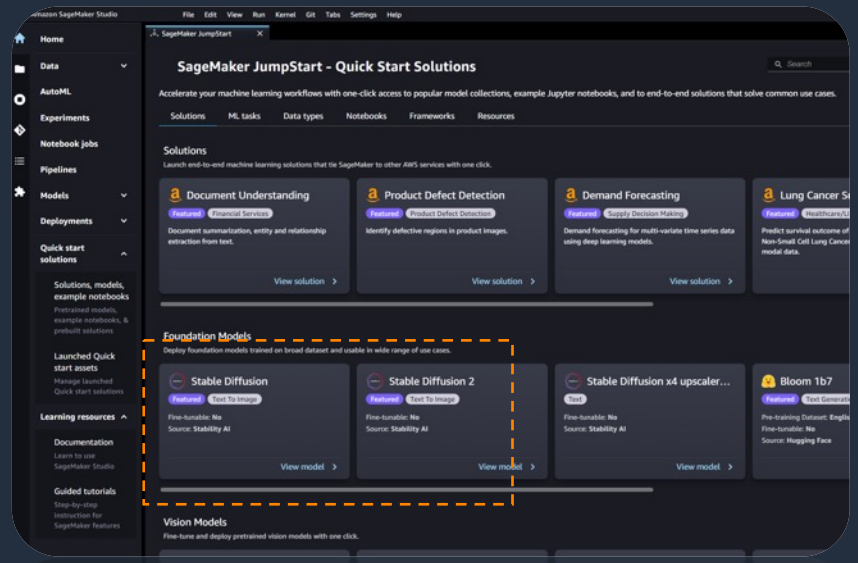

【デモ】SageMaker JumpStart で基盤モデルを簡単に試す

Live デモ実施

SageMaker JumpStart: 基盤モデルを利用する 3 つの方法

SageMaker コンソール (プレビュー)

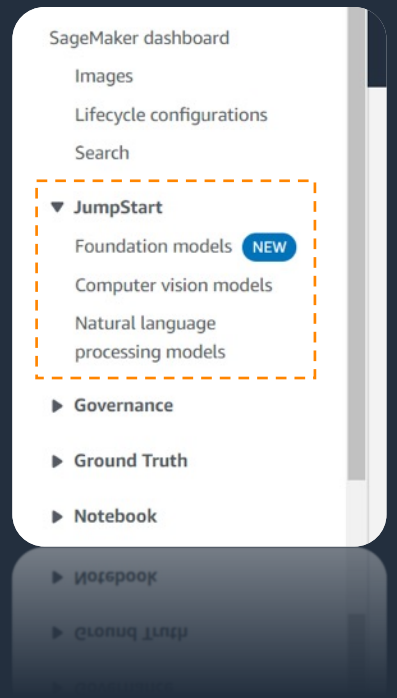

SageMaker ノートブック

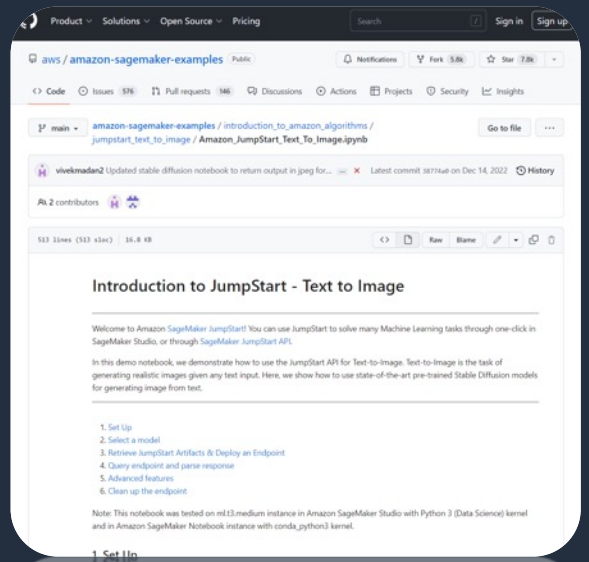

SageMaker Studio
ワンクリックデプロイ

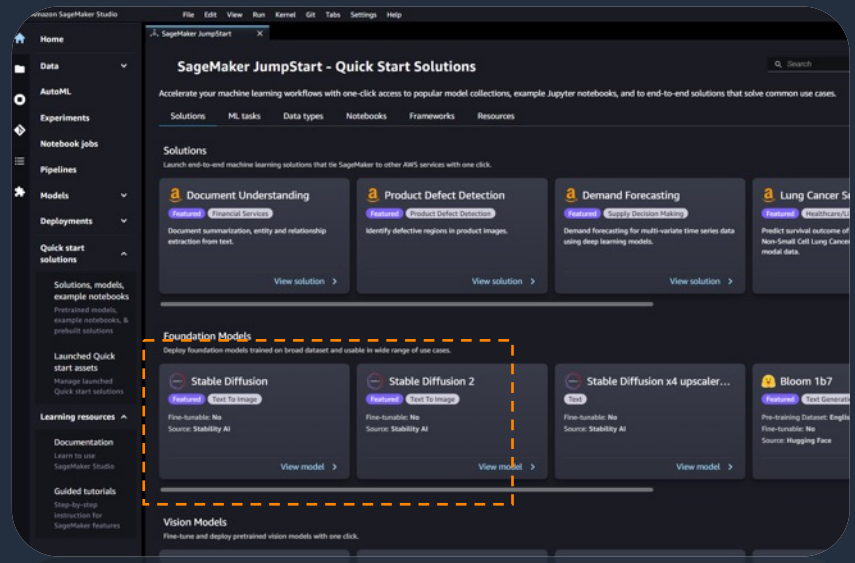

【デモ】SageMaker JumpStart のノートブックを確認する

Live デモ実施

SageMaker JumpStart: 基盤モデルを利用する 3 つの方法

SageMaker コンソール (プレビュー)

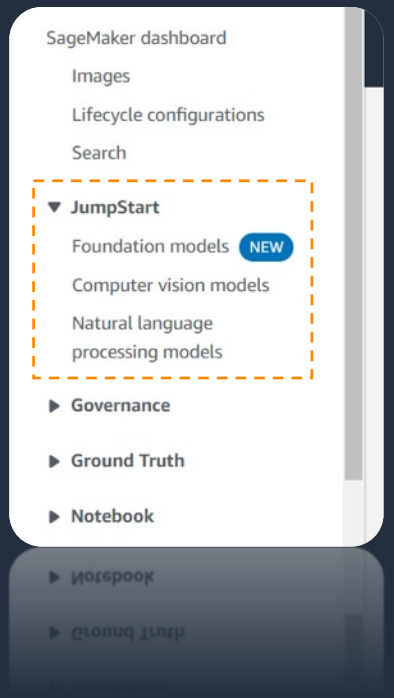

SageMaker ノートブック

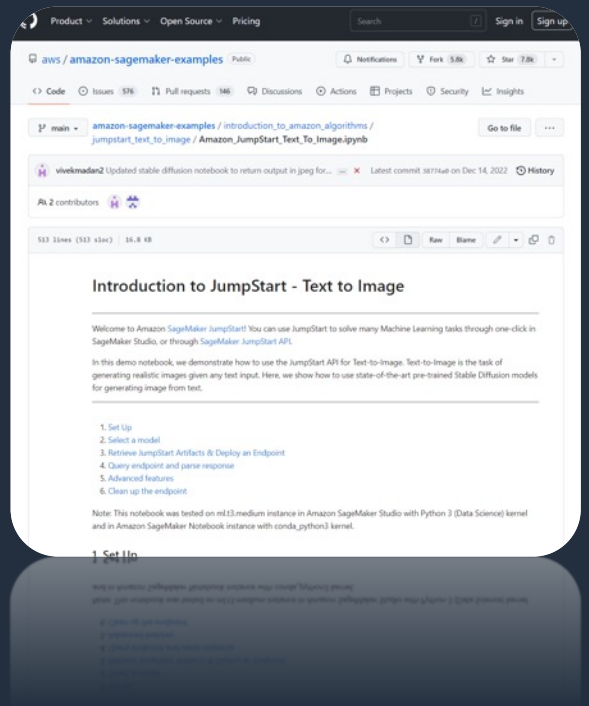

SageMaker Studio
ワンクリックデプロイ

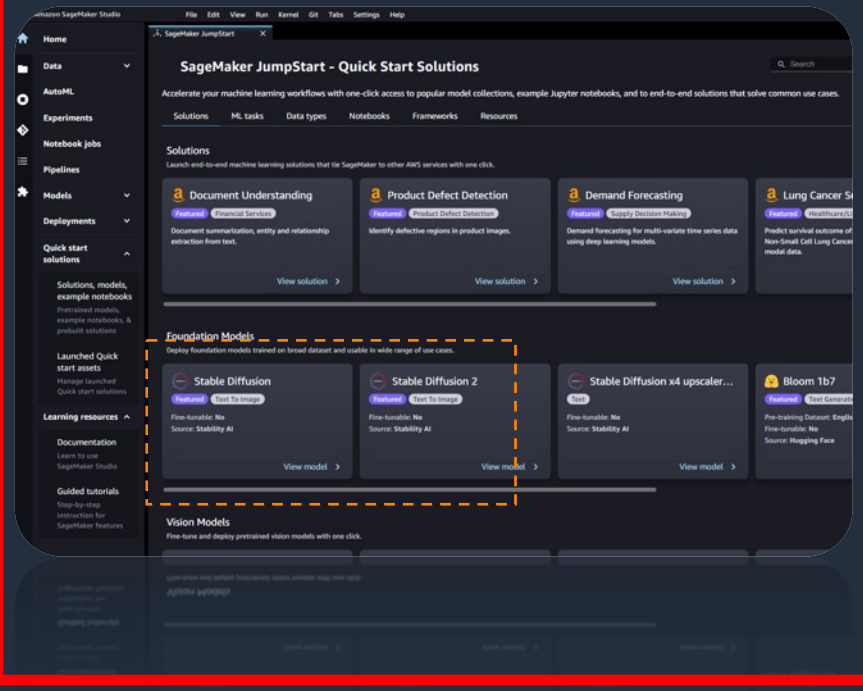

【デモ】SageMaker Studio からワンクリックデプロイする

Live デモ実施

基盤モデルを簡単に試したり、デプロイできるのはわかったけど…

実際の業務やアプリケーションにどうやって使うの？

アジェンダ

- 様々な公開済み基盤モデルを簡単に試す
- GUI からワンクリックで AWS 環境に 生成系 AI モデルをデプロイする
- 生成系 AI を活用したアプリケーションの紹介
  - 社内ドキュメントからの回答文生成
  - コールセンターでの通話要約文生成
- 開発者向けコード生成ソリューションの紹介

生成系 AI を活用したアプリケーション1

社内ドキュメントからの回答文生成

アプリケーション概要 Retrieval Augmented Generation (RAG)

ユーザーからの質問に対して、社内ドキュメントを基にした回答を生成する

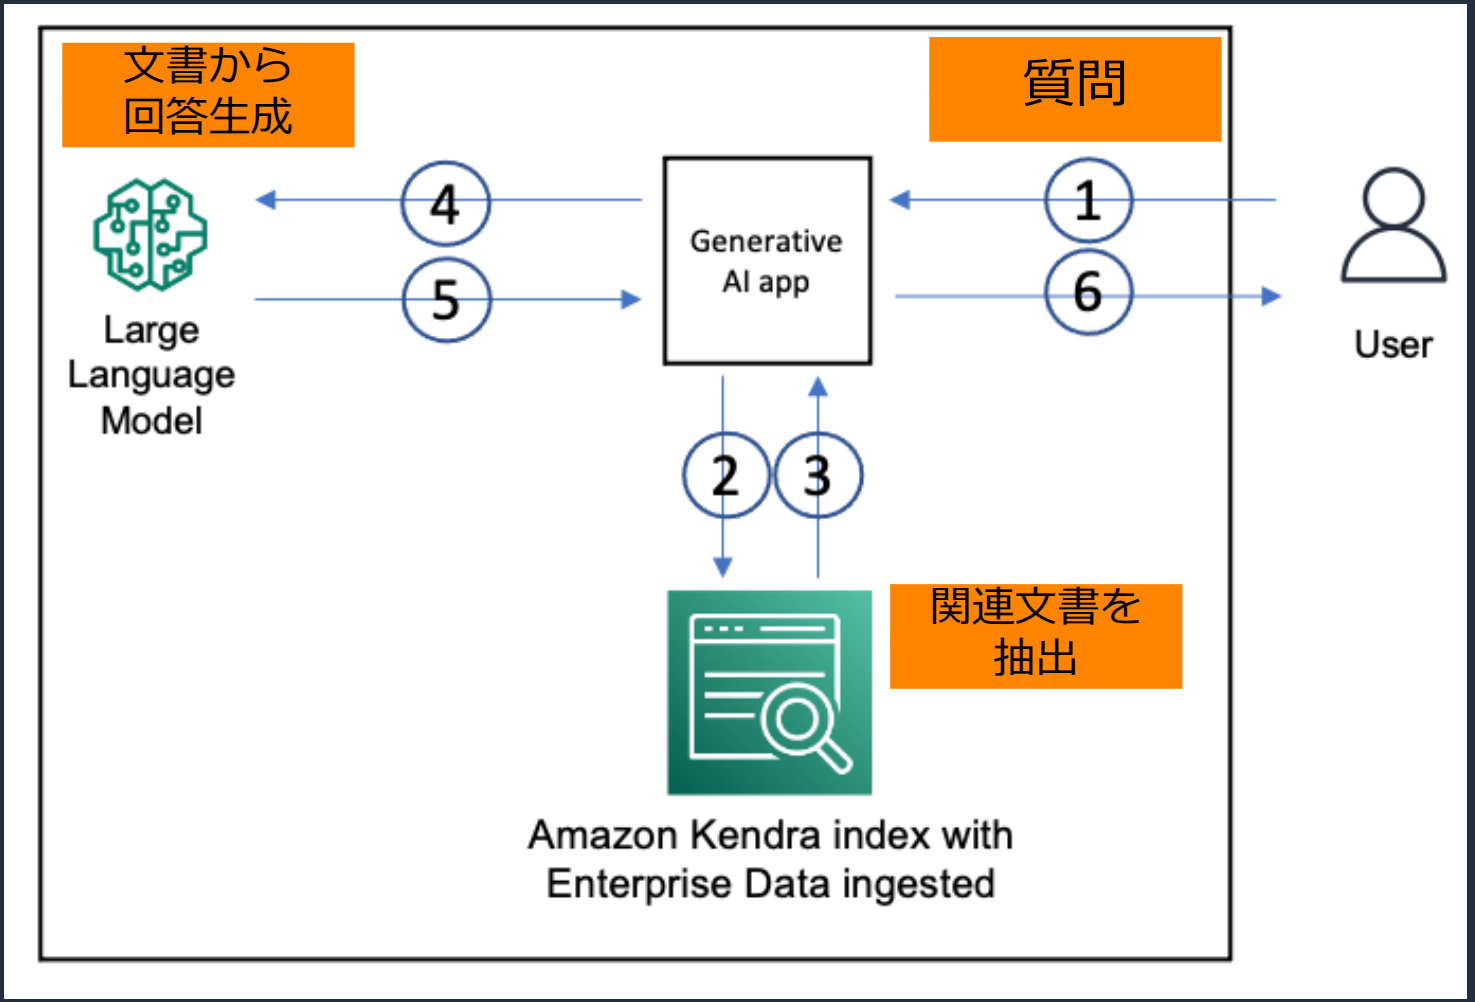

1. ユーザーが社内向け質問文をアプリケーションに入力

2. 3. アプリケーションは Amazon Kendra を利用して、関連するドキュメントを抽出

4. 5. アプリケーションは抽出されたドキュメントを生成系 AI にインプットし、生成系 AI が生成した回答を受領する

6. ユーザーはアプリケーションから生成された回答と、参考ドキュメントリンクを得る

https://aws.amazon.com/blogs/machine-learning/quickly-build-high-accuracy-generative-ai-applications-on-enterprise-data-using-amazon-kendra-langchain-and-large-language-models/

生成系 AI の利用パターン

デプロイされた自社環境のモデルを利用したり、外部モデルを API 経由で利用する

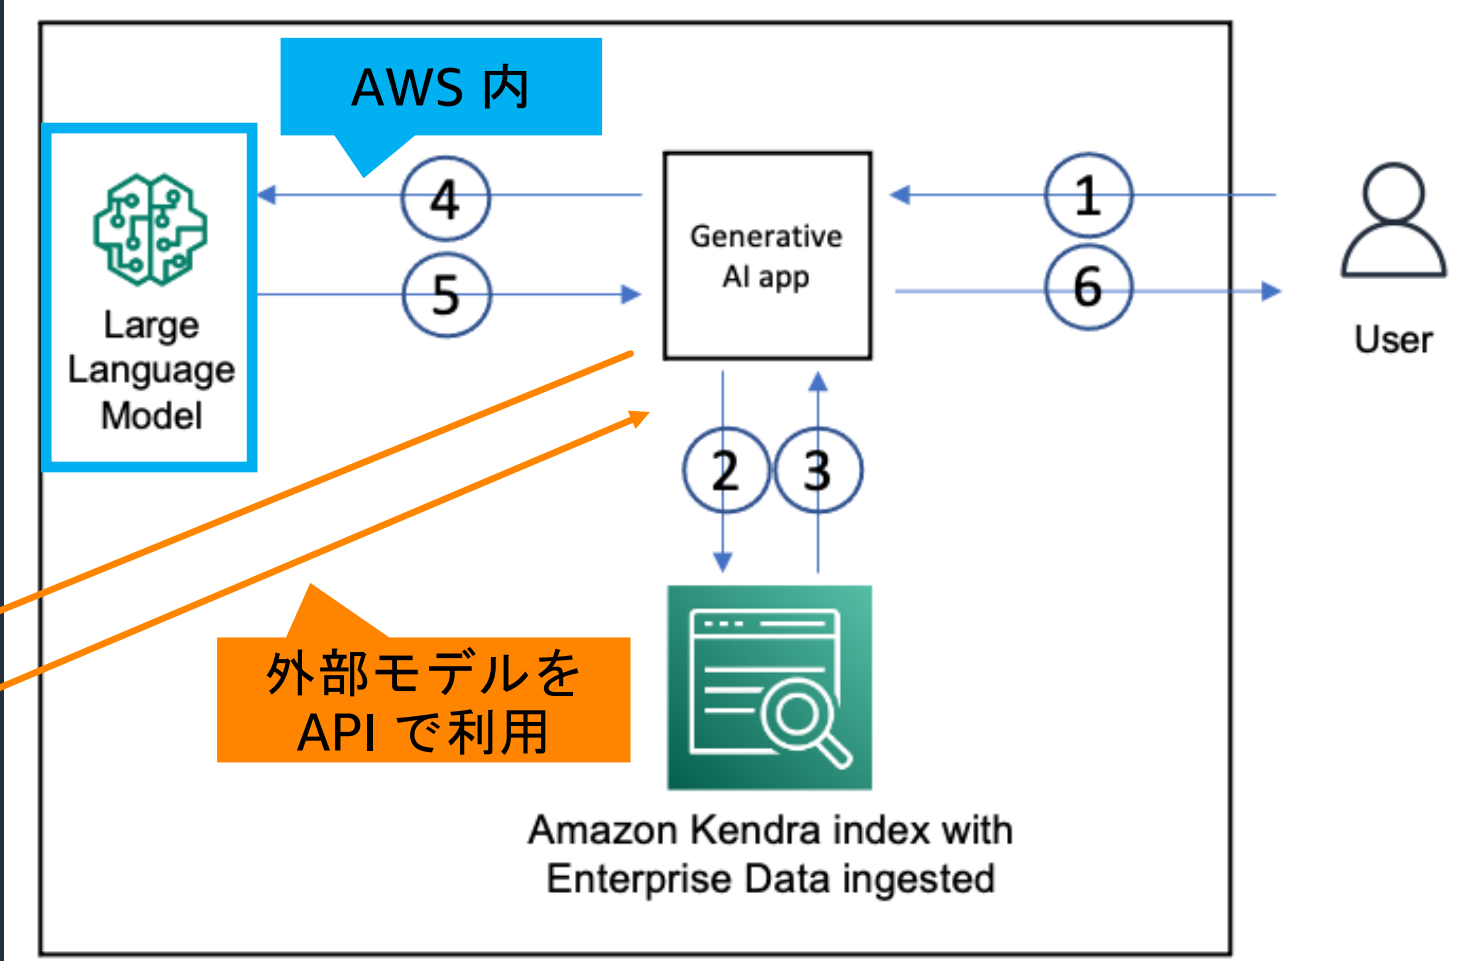

利用パターン1
自社 AWS 環境内の SageMaker エンドポイントにデプロイした生成系 AI を使う

利用パターン2
自社 AWS 環境にはない外部の生成系 AI を、API 経由で使う

【デモ】社内ドキュメントからの回答文生成

Live デモ実施

アプリケーションのポイント

- 生成系 AI をコンポーネントとして利用できるようにアプリケーションを構成し、柔軟な試行錯誤を実現する
- 生成系 AI を他のサービスと組み合わせることで、機能を拡げる
- Amazon SageMaker にモデルをデプロイすることで、自社 AWS 環境内でデータの流れを作る

生成系 AI を活用したアプリケーション2

コールセンターでの通話要約文生成

アプリケーション概要

通話のリアルタイム書き起こし、感情分析、参考ドキュメント提示、通話内容要約などの機能を提供

分析ダッシュボード

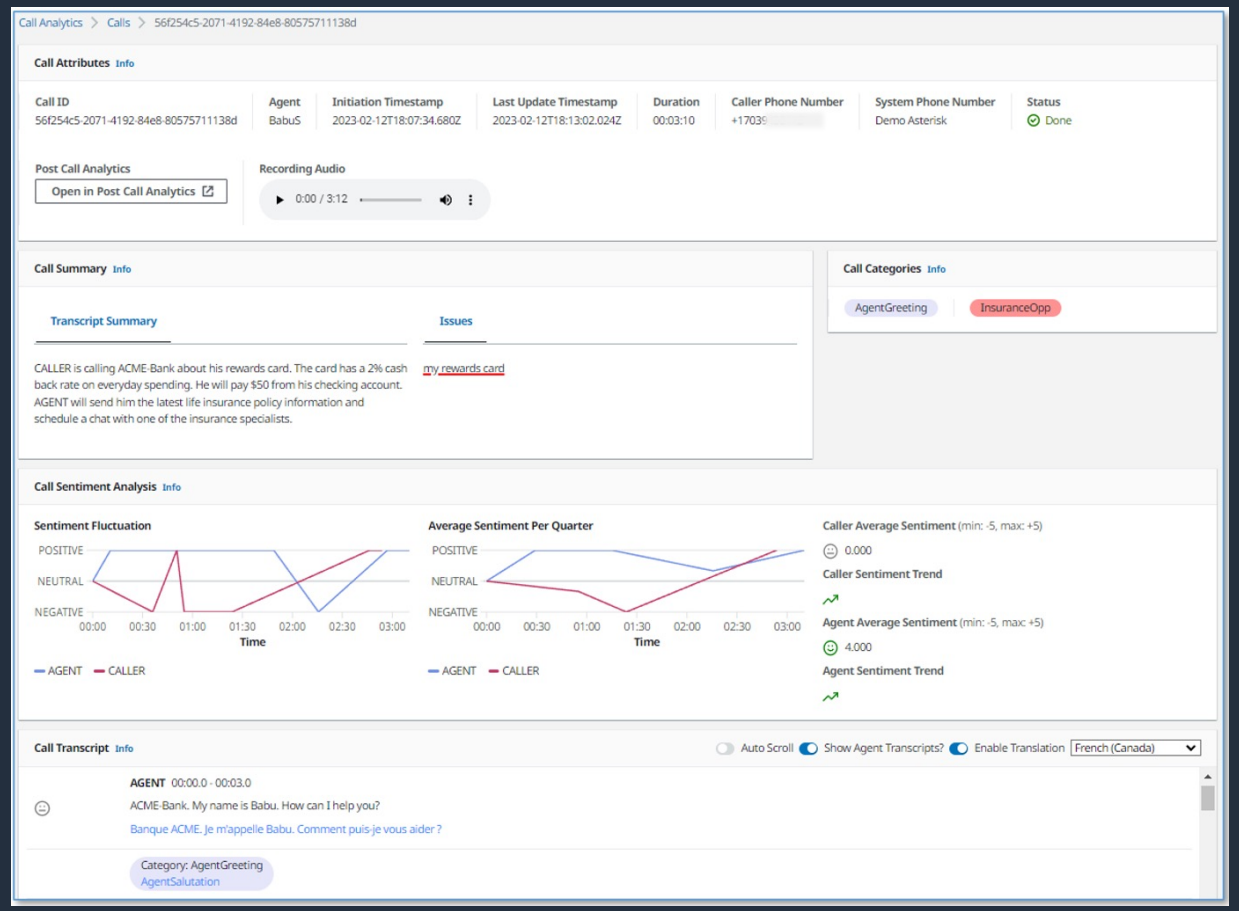

アーキテクチャ

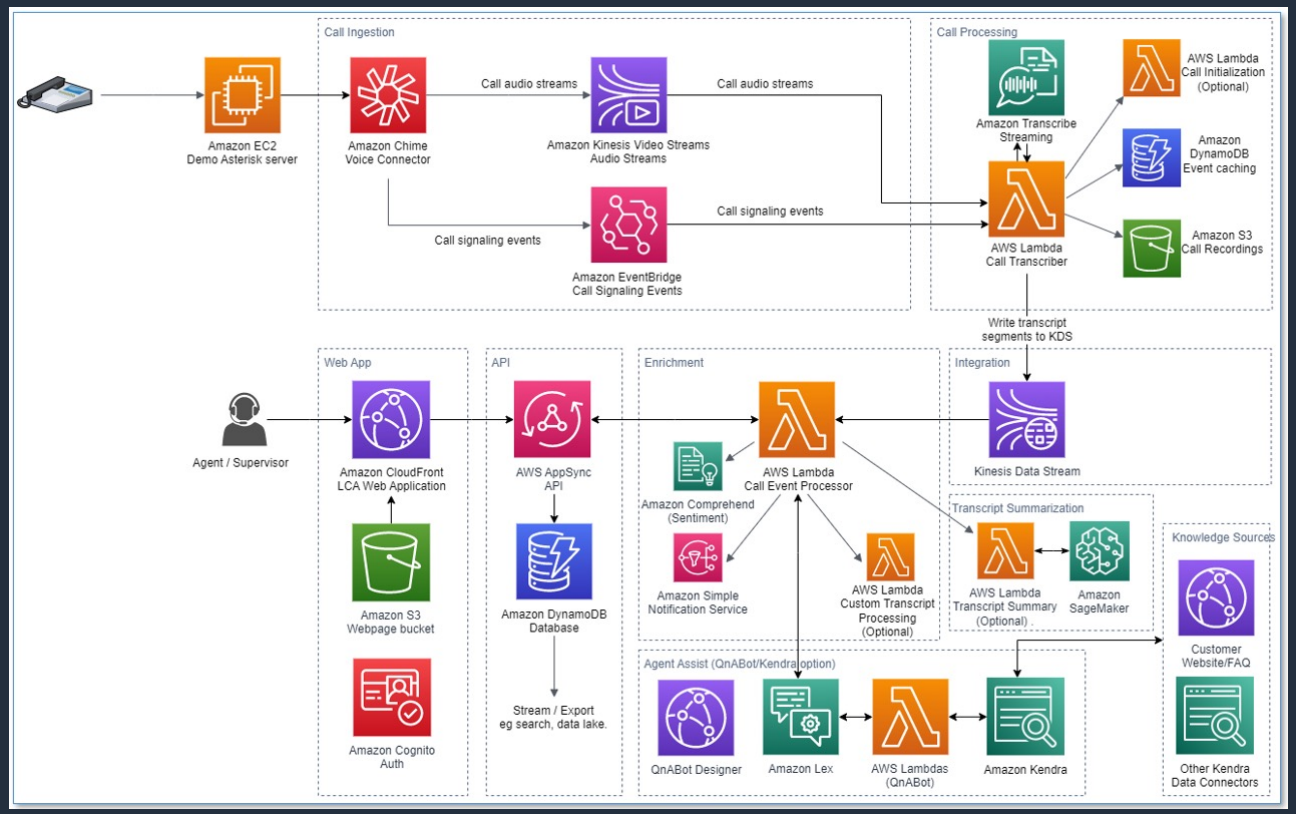

https://aws.amazon.com/blogs/machine-learning/live-call-analytics-and-agent-assist-for-your-contact-center-with-amazon-language-ai-services/

分析ダッシュボードの説明

実際の通話音声を確認

生成系 AI による通話の要約文

発話ごとの感情推移

リアルタイムでの音声書き起こし

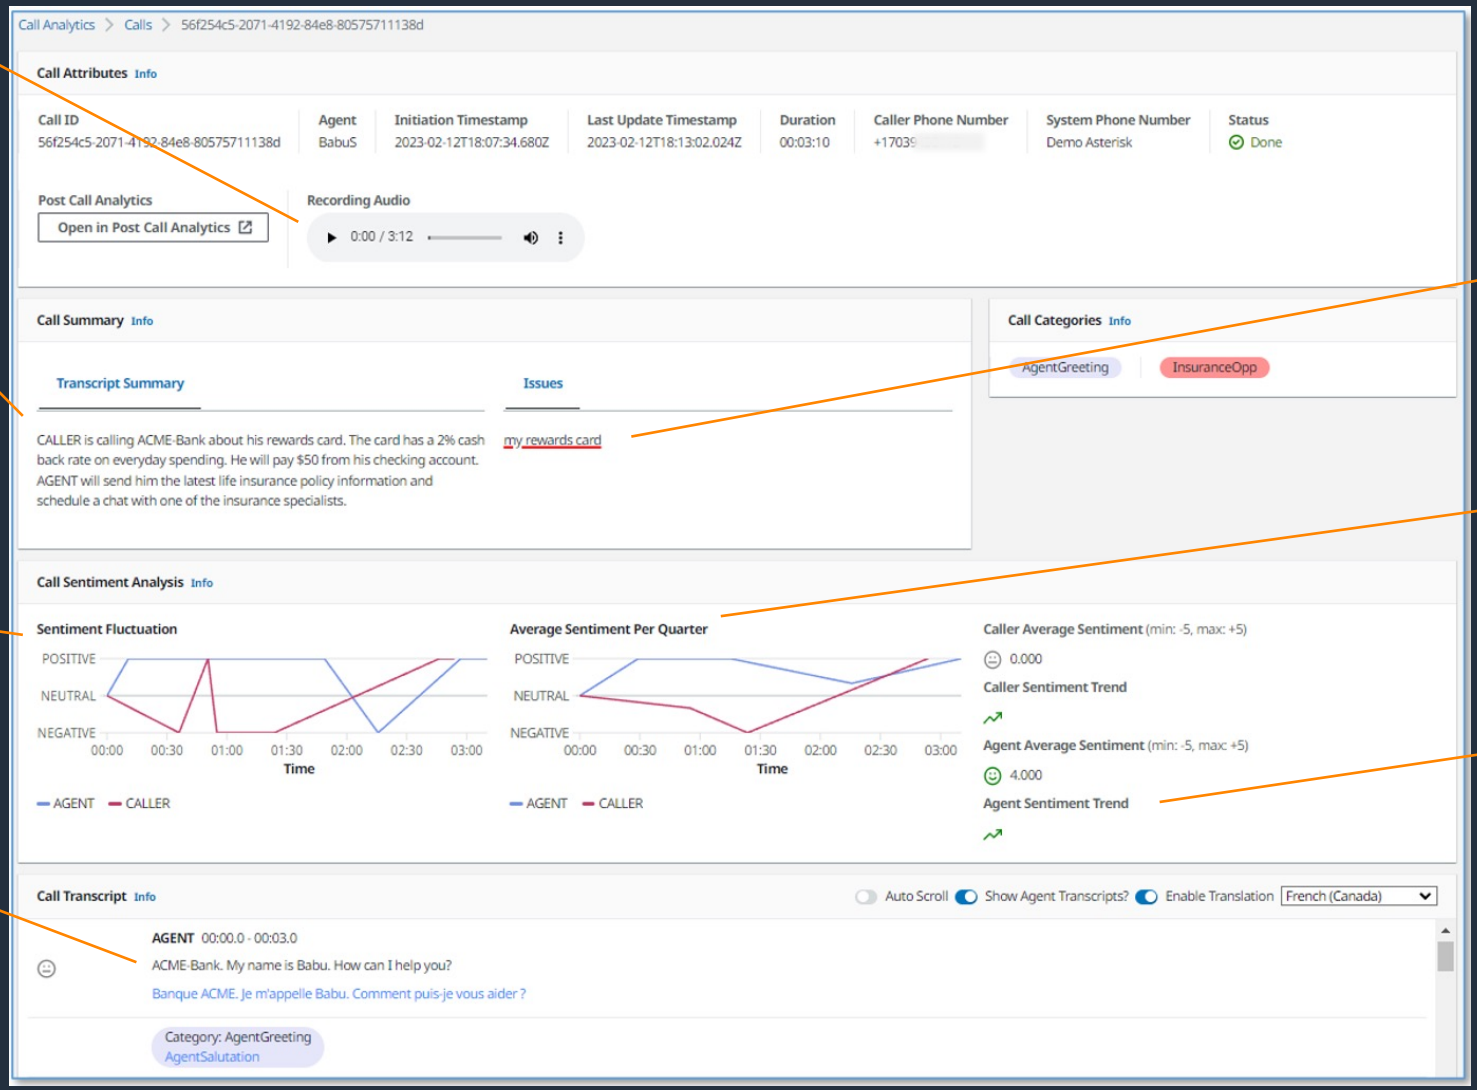

問題を検知して提示（英語のみ対応）

感情の15秒平均推移

感情のセッション平均スコアと推移トレンド

アーキテクチャの説明

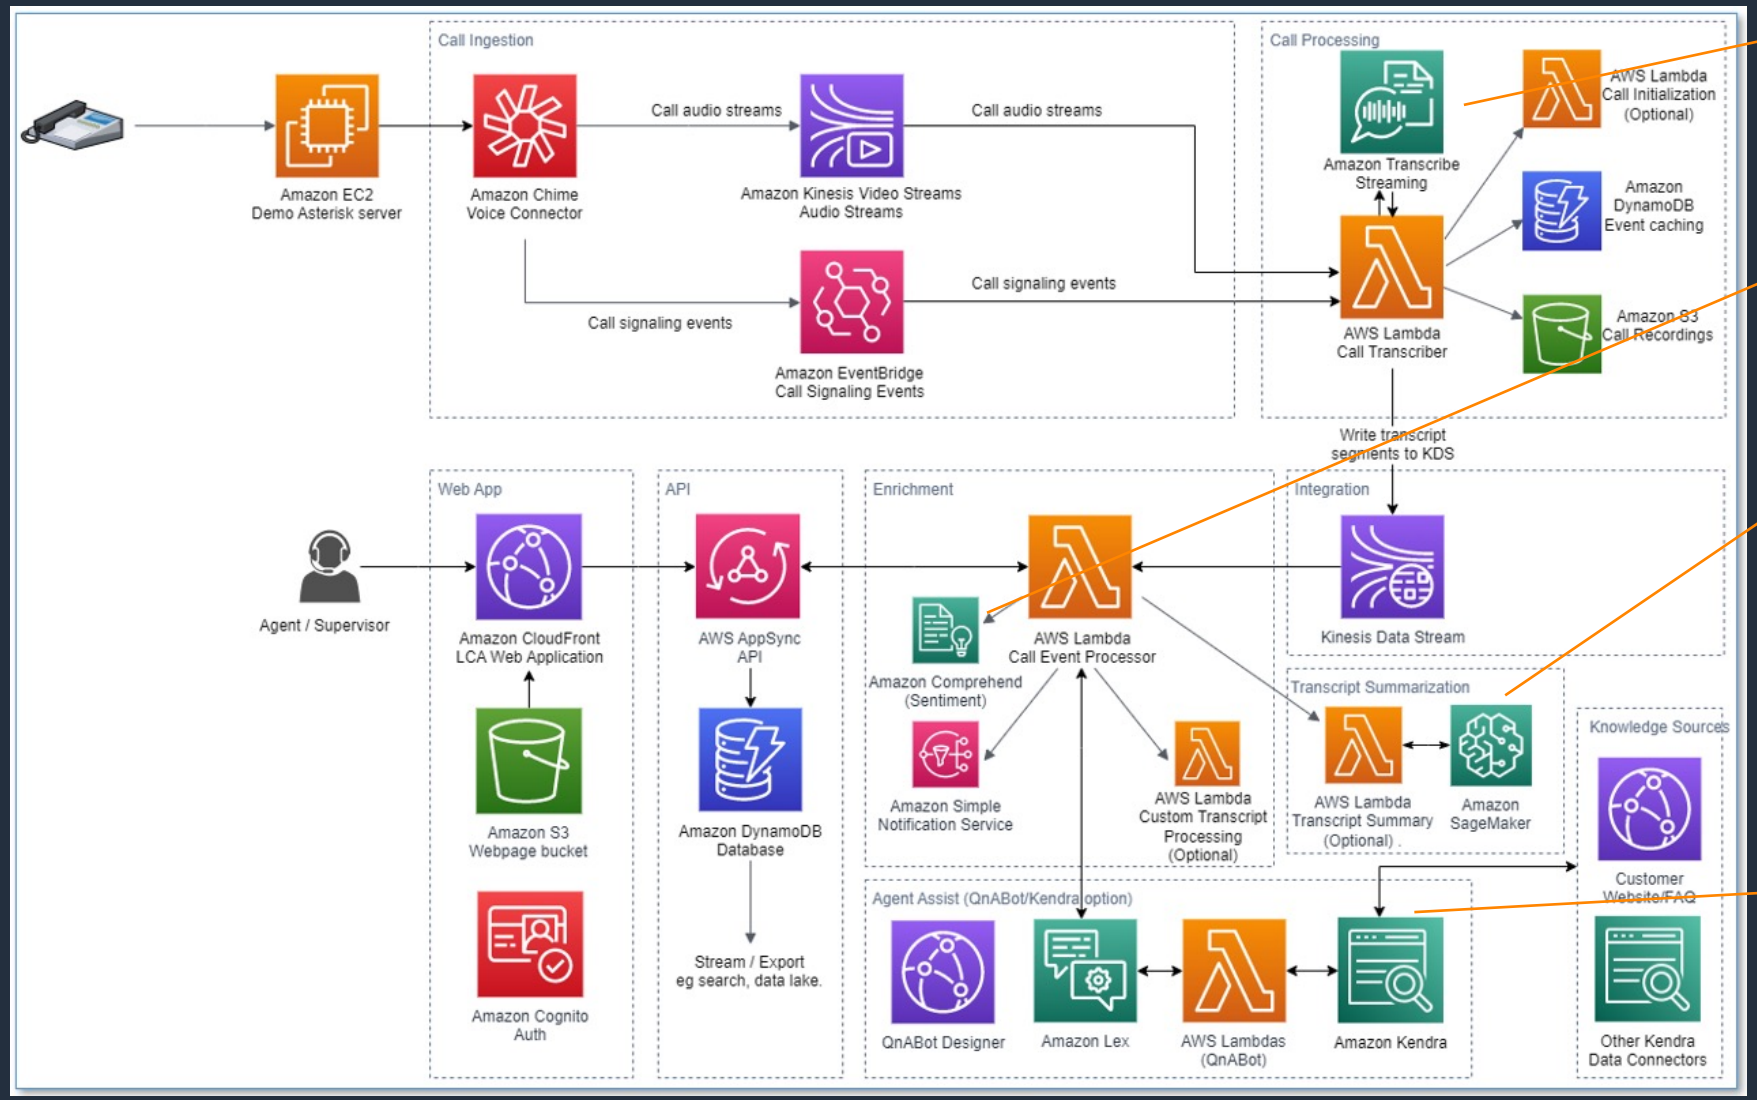

リアルタイム音声
書き起こし
(Amazon Transcribe)

感情分析
(Amazon Comprehend)

通話要約文生成モデル
(SageMaker エンドポイント)

参考ドキュメント提示
(Amazon Lex
& Amazon Kendra)

【デモ】コールセンターでの通話要約文生成

録画デモ実施

生成系 AI モデルの出力を日本語に変換して利用する

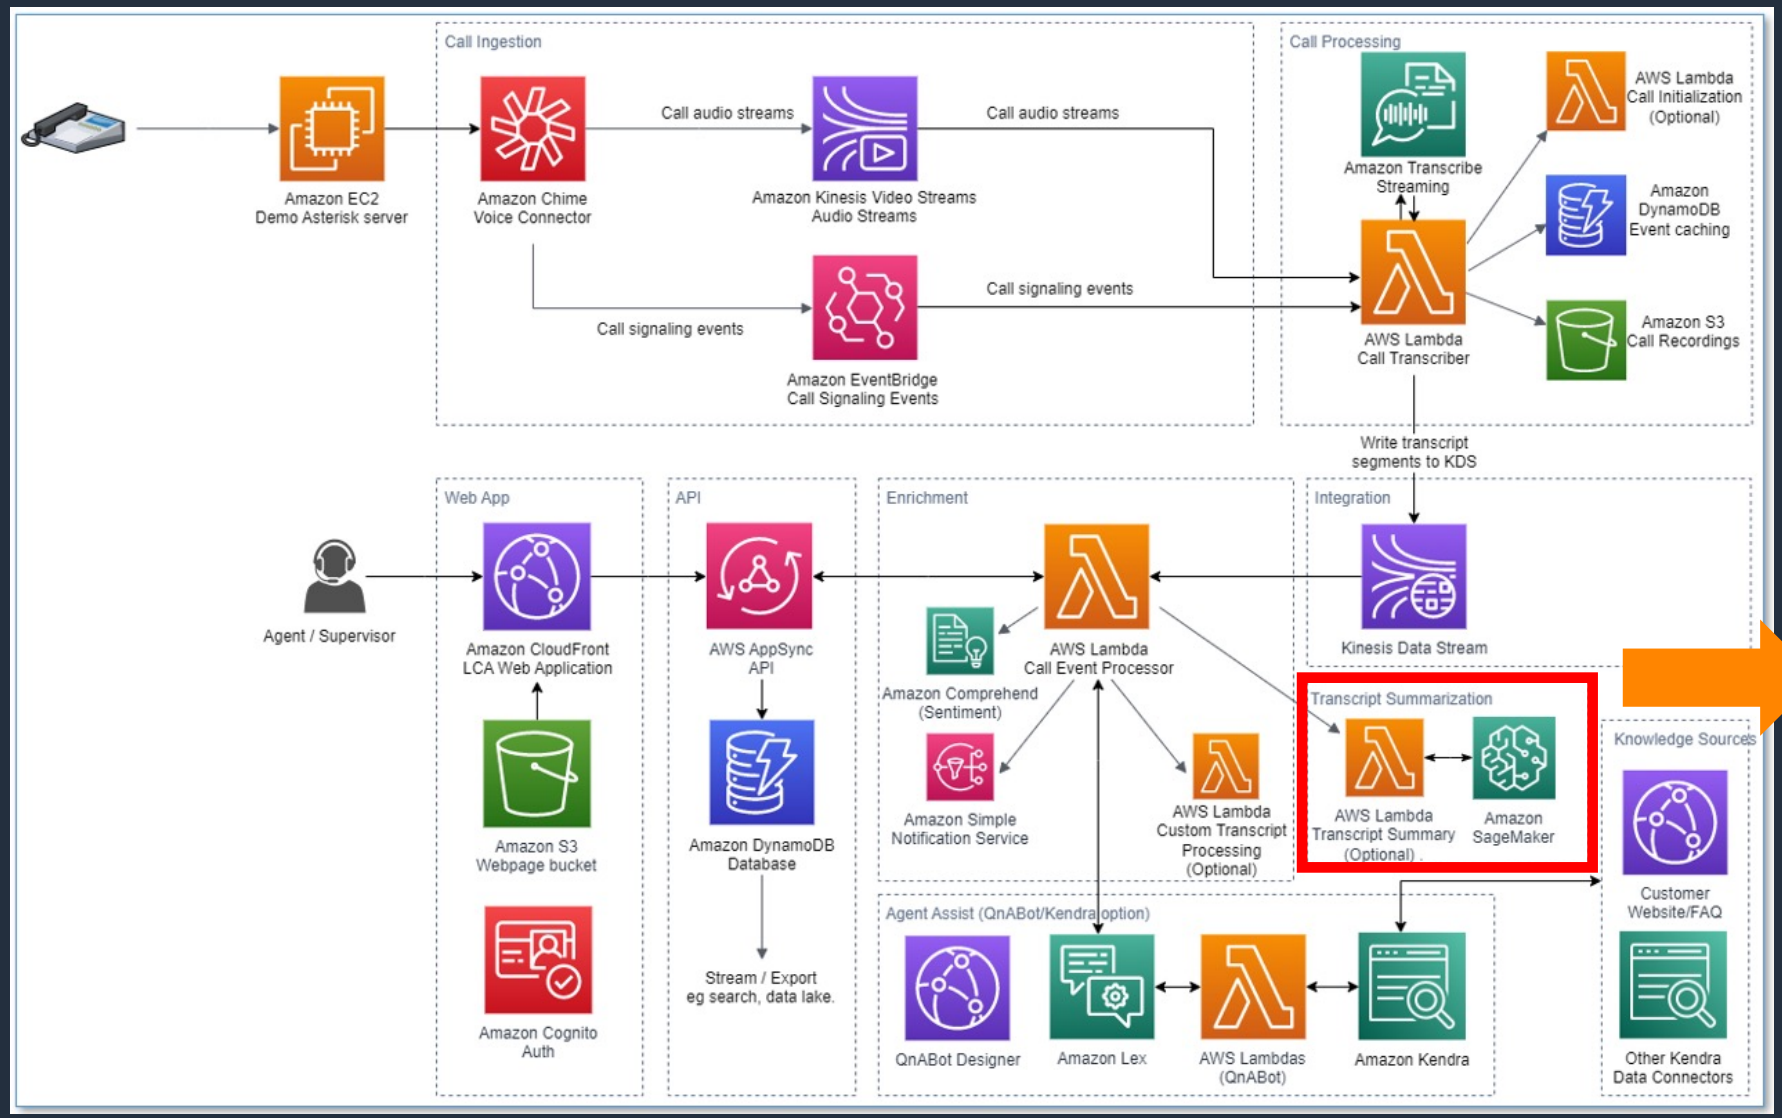

翻訳機能を入力・出力に加える

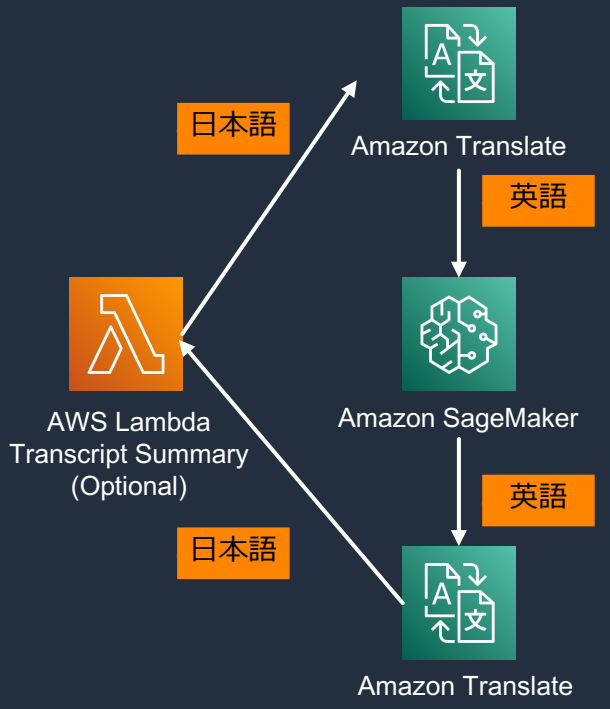

参考：日本語出力変換 – 修正した Lambda 関数

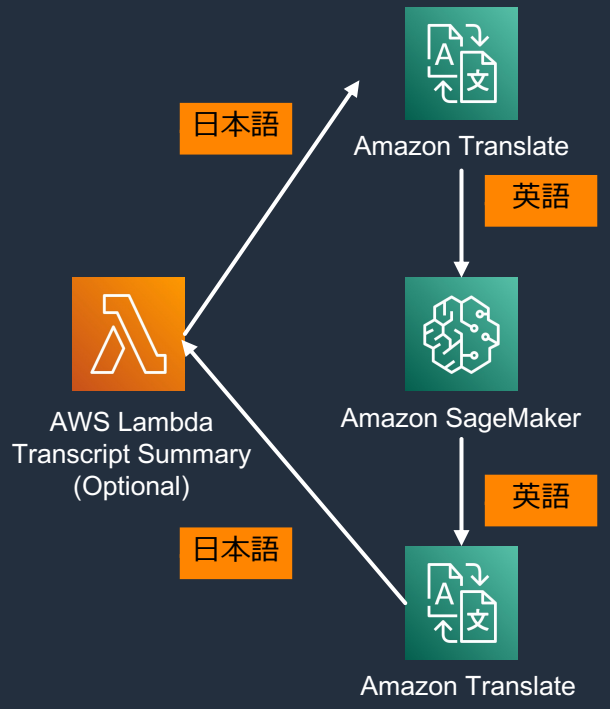


```
def lambda_handler(event, context):
    print("Received event: " + json.dumps(event, indent=2))

    # Setup model input data using text (utterances) received from LCA
    data = json.loads(json.dumps(event))
    callId = data['CallId']
    transcript_response = get_transcripts(callId)
    transcript_data = transcript_response['Payload'].read().decode()
    transcript_json = json.loads(transcript_data)
    # print(transcript_json)

    translate = boto3.client('translate')
    response = translate.translate_text(
        Text=transcript_json['transcript'],
        SourceLanguageCode='ja',
        TargetLanguageCode='en'
    )

    #payload = {'inputs': transcript_json['transcript']}
    payload = {'inputs': response['TranslatedText']}

    summaryText = ""
    try:
        data = json.dumps(event)
        response = runtime.invoke_endpoint(EndpointName=ENDPOINT_NAME,
                                           ContentType='application/json',
                                           Body=bytes(json.dumps(payload), 'utf-8'))
        # print(response)
        result = json.loads(response['Body'].read().decode())

        if len(result) > 0:
            summary = result[0]
            # print("Summary: " + summary["generated_text"])
            summaryText = summary["generated_text"]
        else:
            print("No Summary")
            summaryText = "No summary"

    except Exception as e:
        print("An exception occurred:", e)
        summaryText = ""

    response = translate.translate_text(
        Text=summaryText,
        SourceLanguageCode='en',
        TargetLanguageCode='ja'
    )
    #return {"summary": summaryText}
    return {"summary": response['TranslatedText']}
```

＜Lambda 関数設定手順＞

1) Lambda 関数の検索窓で、”SageMakerT-Lambda”で検索

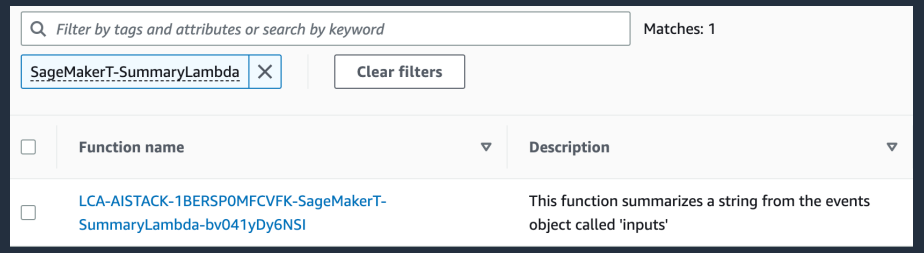

2) index.py の、lambda_handler関数内を左の通り変更

3) Lambda の Execution role に “TranslateFullAccess” を付与

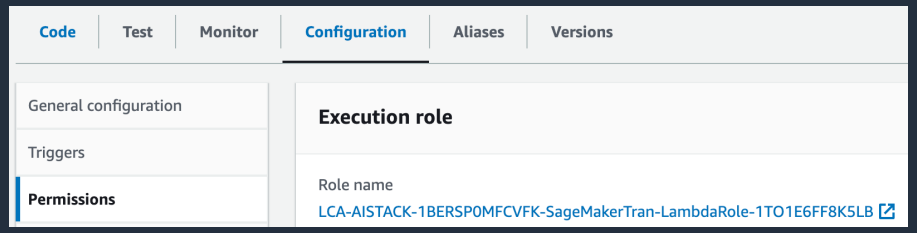

参考：その他アプリケーション構築のTIPS

- CloudFormation テンプレートの設定パラメータ
  - Admin Email Address：eメールアドレス
  - Authorized Account Email Domain(s)：eメールアドレスのドメイン
  - Allowed CIDR Block for Demo Softphone：<接続元（自宅）のIP>/32
  - Call Audio Recordings Bucket Name：S3バケットを事前に作成し、指定
  - Transcribe API mode：standard
  - Language for Transcription：ja-JP
  - End of Call Transcript Summary：SAGEMAKER

- Soft Client：Zoiper5 を利用（オペレータ・AGENT側）
  - https://github.com/aws-samples/amazon-transcribe-live-call-analytics/blob/develop/lca-chimevc-stack/Asterisk.md

- Skype（カスタマー・CALLER側）
  - 設定した Zoiper5 にダイヤル

アプリケーションのポイント

- 生成系 AI をコンポーネントとして利用できるようにアプリケーションを構成し、柔軟な試行錯誤を実現する

- 生成系 AI を他のサービスと組み合わせることで、機能を拡げる

- Amazon SageMaker にモデルをデプロイすることで、自社 AWS 環境内でデータの流れを作る

NEW

- 翻訳機能と組み合わせることで、英語のみ対応のモデルから日本語出力を得ることも可能（要件を満たすかは検討）

NEW

- 要件を満たすには、どこまで大規模なモデルが必要なのか検討する

アジェンダ

- 様々な公開済み基盤モデルを簡単に試す
- GUI からワンクリックで AWS 環境に 生成系 AI モデルをデプロイする
- 生成系 AI を活用したアプリケーションの紹介
  - 社内ドキュメントからの回答文生成
  - コールセンターでの通話要約文生成
- 開発者向けコード生成ソリューションの紹介

NEW

Amazon CodeWhisperer

AI コーディング・コンパニオンで
アプリケーションをより速く、
より安全に構築

Amazon CodeWhisperer: 一般公開され、個人開発者は無料で使用できるようになりました!

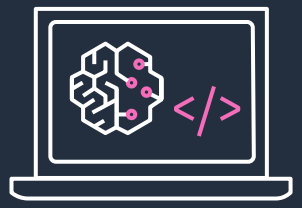

コードの候補を
リアルタイムで生成

コードをスキャンして、発見の
困難な脆弱性がないか調べる

オープンソースのトレーニング
データに似たコードにフラグを
たて、フィルタリングする

Amazonによるプレビュー中、生産性向上課題に対し、CodeWhisperer を使用した参加者は、CodeWhisperer を使用しなかった参加者に比べて、タスクの正常完了率は 27% 高く、平均で 57% も速く完了しました。

【デモ】Amazon CodeWhisperer

SQSIdentityFunction.java M src/main/java/com/amazonaws/services/sqs/SQSIdentityFunction.java

```
package com.amazonaws.services.sqs;

import java.util.Map.Entry;
import java.util.stream.Collectors;

import com.amazonaws.services.lambda.runtime.Context;
import com.amazonaws.services.lambda.runtime.RequestHandler;
import com.amazonaws.services.lambda.runtime.events.SQSEvent;
import com.amazonaws.services.lambda.runtime.events.SQSEvent.MessageAttribute;
import com.amazonaws.services.lambda.runtime.events.SQSEvent.SQSMessage;
import com.amazonaws.services.sqs.model.MessageAttributeValue;
import com.amazonaws.services.dynamodbv2.AmazonDynamoDBClientBuilder;
import com.amazonaws.regions.Regions;

/* */
```

参考：YouTube でのLiveデモもぜひご覧ください

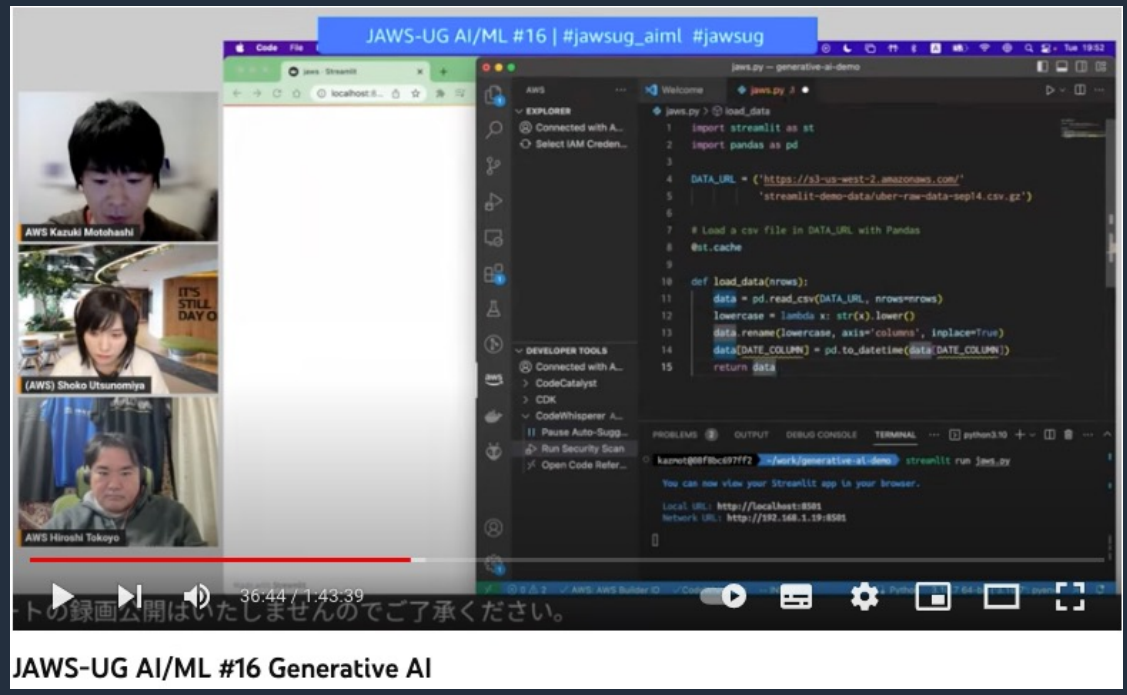

JAWS-UG AI/ML #16 Generative AI

https://www.youtube.com/watch?v=PkZenNAXtYs&t=2170s

https://aws.amazon.com/blogs/aws/amazon-codewhisperer-free-for-individual-use-is-now-generally-available/

まとめ

生成系 AI の活用アイディアとシステムとして考慮すべき点を知る

- 要件を満たす生成系 AI モデルを目利きする
  → 手軽に試すためなら、SageMaker JumpStart

- 他機能と組み合わせてアプリケーションでできることを拡張するために、柔軟性の高いシステム構成を考慮する
  → ビルディングブロックで構成できる AWS を活用

- SageMaker エンドポイントに生成系 AI モデルをデプロイすることで、データの流れを自社 AWS 環境内で完結することが可能
  → Amazon SageMaker はデプロイ後の運用(MLOps)機能もサポート

Thank you!