


# AWSの生成AI

一社一社の課題に応える  
3階建てのクラウドサービス  
【ダイジェスト版】

黒川 亮・呉 和仁 [共著]  
アマゾン ウェブ サービス ジャパン合同会社 [監修]



リックテレコム

AI/Data  
Science  
実務選書



非売品

※このドキュメントは2024年秋刊行予定の書籍『AWSの生成AI（仮題）』のダイジェストです。書籍の一部を抜き出し、発売に先行してその骨子だけをお披露目する無償のプレリリース版であり、予告編のようなものです。

## Contents

はじめに .....	3
<b>第1章 生成AIとAWSの生成AI</b> .....	(黒川 亮)
1.1 日本の課題 .....	6
1.2 生成AIとは? .....	8
1.3 Amazonにおける生成AI活用例 .....	11
1.4 AWSが提供する生成AIサービス .....	14
<b>第2章 責任あるAI</b> .....	(黒川 亮)
2.1 生成AIのリスクと責任あるAI .....	21
2.2 生成AI活用に伴う主なリスク .....	26
2.3 新たなリスクと課題をどう解決するか? .....	30
<b>第3章 アーキテクチャ図に見るユースケース</b> .....	(黒川 亮)
3.1 顧客体験の向上 .....	41
3.2 社員の創造性と生産性向上 .....	45
3.3 生成AIアプリケーションに取り組むには? .....	49
<b>第4章 Amazon Bedrockで生成AIに触れる</b> .....	(呉 和仁)
4.1 改めて Amazon Bedrockとは? .....	55
4.2 Amazon Bedrockの利用準備 .....	57
4.3 AWSのコンソールから使う .....	64
4.4 APIから Amazon Bedrockを使う .....	73
4.5 アプリケーションでの利用例とユースケース .....	81
結びにかえて .....	87

# はじめに

---

インターネットでの買い物に多くの人がまだ不安を抱いていた時代に、Amazonでの安心・安全な買い物を支えるために設立されたのがAWS（Amazon Web Services）です。増え続ける取り扱い商品やサービスの品揃え、消費者と出品者の利便性、選べる最適価格の追求を長年支え続けた結果、「AWSで培われた技術を自分の会社でも使いたい」という要望が寄せられるようになりました。現在、AWSは200以上のサービスを世界中の企業に提供しています。

さて、私たち日本の企業は、これまで何度も「今年こそ業務革新、働き方改革！」と意気込んで、DX（デジタルトランスフォーメーション）や次々登場する新しい技術に挑み、検証しているうちに、だんだんと疲れてしまったようです。最近も、話題の生成AIを自社で試せるのか、使いこなせるのか、またも挑み、検証し、早くも疲れ始めているようです。

これまで私たちは、新しい技術を見ると、つい自分の持ち場や役割を離れて、技術に自分の仕事を合わせてみるのですが、やがて違和感を覚え、次第に使わなくなっていたのではないのでしょうか。人間の顔が一人一人違うように、企業の仕事も解決すべき課題も各社各様です。生成AIについても、満足のいく回答精度、支払える対価、イラッとしない回答時間を十把一絡げにはできず、正しい唯一の答えなどないのです。

一社一社の目指す成果やゴールは違います。「自社の仕事に合った生成AIは何だろう」、「多様な選択肢があっという間ではないか」と企業が考えるきっかけを作りたいと思ったのが、この本を企画した動機です。

筆者はAWSで、AI技術を使った新事業をお客様と一緒に企画し、開発する仕事をしています。短期的な生成AIのお試しから、長期的に事業の差異化につなげるために、数百の企業一社一社の仕事に必要なAIの精度・コスト・回答速度を、いわば「かかりつけ医」の立場で考え、AIの専門家へ橋渡ししてきました。生成AIは非常にスピードの早い分野であり、2週間ごとに新しい技術や挑戦が生まれます。導入企業やサービス利用者から教わることもたくさんあります。

筆者はこの本の中で、お客様と見つけた生成AI活用のヒントを、広範な読者の皆さんに向け開示していこうと思います。様々な企業で、一人一人が十人十色の仕事に向き合っているなか、誰もが知っておくべき「生成AI基本のキ」から始めます。皆さんが自分にとっての生成AI活用をイメージでき、より快適に仕事が進む未来を想像できるようになれば幸いです。



# 第 1 章

## 生成AIとAWSの生成AI

# 1.1 日本の課題

---

はじめに、2023年に生成AIが日本でブームとなった背景を見ていきたいと思います。AWSは世界各地に拠点を持っているので、世界との比較も踏まえてお話しします。

日本では少子高齢化が進み、人材確保が難しくなっているとされています。実際、日本が空前の株価と好景気に沸いた1980年と比較してみると<sup>1)</sup>、全人口に占める20代から30代の割合は、3人に1人から、2025年には5人に1人にまで減少しています。多種多様な製品・サービスを提供するために求められる人材の条件が高度になる一方で、仕事の担い手は減少しているため、今現場で働いている社員の負担が増えています。

また、日本の総人口が1980年も2025年も約1.2億人と大きく変わらない一方で、世界の人口は約45億人から約79億人にまで急激に増加しています。世界2位の経済大国だった時代は、日本国内の売上が大きく、世界の中でも日本の意見が聞かれやすい環境でした。現在、世界に占める日本の人口は1.5%まで下がり、海外市場の成長に活路を求める日本企業が増えています。

はじめて見る海外の規制・法令や、目まぐるしく進む技術革新を受けて、多様化する顧客の問い合わせに 대응するために、社員に必要とされる前提知識は年々増えています。その結果、必要な情報を探す時間がどんどん長くなり、今では平均して1週間の40%を情報検索に費やしている<sup>2)</sup>とされています。その背景として、これまで顧客の問い合わせに対応してきた社員の3人に1人が65歳以上となり、ベテランの知識や技術が残されないまま退職してしまったり、業務マニュアルとして残っていても社内で共有されていなかったり、検索可能なデータとして整備されていなかったりと、筆者も多くのお客様から苦労話を聞いています。

若者の人口が減る中で、移民受け入れにも慎重な日本では、人手不足の解消や情報検索の特効薬として、2023年、人と比べても違和感のない答えを返す生成AIが大きく取り上げられ、朝のニュースでも報道されるほどのブームとなりました。生成AIという言葉が知らなくても、米国で開発された「ChatGPT」の名は聞いたことがあるでしょう。

その中身を知らなくても、まず、「生成AIもAIの一種」と覚えてください。AIはデータで育ちます。世界的に人口とデータが増え続ける中で、データ量の違いはAIの性能にも影響します。英語：15.3億人、中国語：14.7億人、スペイン語：5.2億人、アラビア語：4.5億人、フランス語：4.3億人<sup>3)</sup>といった具合に、日本語の3.6倍から12.8倍の母数を持つデータで鍛えられたAIが各国で

---

1) 出典：白書・審議会データベース 津田塾大学総合政策学部  
<https://empowerment.tsuda.ac.jp/detail/73889>

2) 出典：Tech Target Enterprise Strategy Group - 『Analyzing the Economic Benefits of Intelligent Search using Amazon Kendra』

3) 出典：【2024年最新版】世界の言語ランキング(ネット人口含む)  
<https://japan.wipgroup.com/media/language-population>

開発されています。母国語以外の第二言語も使用する国々では、世界的に通用する生成AIを目指して日夜新しい発表がなされています。

日本では働き手の減少を踏まえて、これまで人の介在をなくす自動化、勘や経験だけに頼らないデータ活用、様々な需要と供給のギャップを埋めるマッチング利用に取り組んできました。現在、当たらない情報検索の結果に替えて、AIで人間並みの答えを得るために、日本語で正確に回答できる生成AIの開発、埋もれている日本語データを汲み上げる環境整備、ベテラン社員の知見の聞き取りとデータ化が、多くの企業・組織の課題となっています。

もう少し視野を広げると、AIに活用できるデータは言語だけではありません。グラフ、設計図、漫画などの画像データや、広告、商品説明、アニメなどの動画データもあります。日本語のデータ量が他言語と比べて少ないとしても、日本の優れた設計書やコンテンツのデータを基にすれば、世界と伍して戦える日本発・世界初のAIを育成できる可能性があります。言語での遅れを取り戻し、生成AIによる新たな価値創造に取り組んでいくために、プライバシーやセキュリティを守る国際的なAIルールへの対応、中小企業・医療現場・行政事務など優先度が高い分野でのAI利用促進と、AI開発力の強化のためのヒト・モノ・カネの整備が政府<sup>4)</sup>と社会の課題となっています。

---

4) 出典：内閣府 AI戦略会議資料(2023年11月8日)  
[https://www8.cao.go.jp/cstp/ai/ai\\_senryaku/6kai/4aishisaku.pdf](https://www8.cao.go.jp/cstp/ai/ai_senryaku/6kai/4aishisaku.pdf)

# 1.2 生成AIとは？

---

AWSでは、生成AIを次のように定義しています。

「生成AIは、テキストを含む入力(プロンプト)から、人間の創造に近いエッセイ、問題の解決策、リアルな写真、音声、ビデオ、プログラムコード等、各種コンテンツを生成し出力します。また、その実行は、基盤モデルと呼ばれる、巨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します。」

実際の利用現場では、「創造」よりも仕事を「補完」する事例が先行しています。例えば、高齢者からコールセンターに電話があった場合、応対するエージェントのために、高齢な顧客が求めている回答の候補を画面表示して、電話の意図を確認する、15分の会話を5分ごとに要約し表示する、会話の結果を顧客宛てメールや社内報告それぞれの形式と体裁に整えて記録する等です。

また交通機関では、電柱が車両に接触しないように、傾いた電柱を検知できるAIを開発しています。AIはデータで育ちますが、世の中に本当に傾いている電柱とその画像は滅多にありません。そのため、生成AIを利用して傾いている電柱の画像を合成データとして作り出し、検知するAIを育てるために使用します。合成データは、沖縄など取って風雨の強い地域で実施するペンキの剥がれや配管のサビなどの劣化検証などにも利用されています。

## ●生成AIの基盤モデル

次に、生成AIを支える「基盤モデル」について説明します。基盤モデルは、次に来る単語(正確にはトークンと呼ばれるものですが、ここでは詳細は割愛します)を予測する仕組みです。例えば、「風が吹けば」と入力した場合、次の単語が「桶<sup>おけ</sup>」である確率と、「金<sup>かね</sup>」である確率を計算します。このとき、次に続く「儲かる」との文脈と、事前学習した知識の双方から、最も確からしい次の単語を予測して、「桶」と出力します。この結果がテキスト生成であり、次に来る絵柄の確率を計算して1枚の絵に仕上げているのが画像生成です。

画像生成の仕組みは面白く、作成したい画像の説明文とノイズを組み合わせることで、与えたテキストに沿った様々な画像を生成できるようになりました。画像生成では著作権が必ず議論されるので、著作権のない背景の画像を広げて消したい対象を塗りつぶすイン・ペインティングや、元々著作権を持っている画素の粗いコンテンツを4K/8K対応にする高精細化に利用されています。

基盤モデルの仕組みをもう少し詳しく説明します。基盤モデルは、インターネット上の膨大な量のデータを事前に学習しています。単純な計算を行うユニットを大量に用意し、さらにそれを何層も重ねることで、複雑な概念を学習することができます。このユニットそれぞれに学習の対



象となるパラメータが存在しており、ユニットが広く、そして深くなるほどパラメータの数も増える、という関係です。現在ではパラメータの数が数兆に達する基盤モデルもあります。例えばAmazonの場合「アレクサ<sup>5)</sup>、家系じゃないラーメンを探して」と聞いたときに答えてくれるAIのパラメータの数は200億です。

もし、数兆のパラメータを持つ基盤モデルに同じ質問をした場合、100倍以上の計算式を処理するための電力が消費され、二酸化炭素が排出されます。こうしたことから私たちはお客様に「鉛筆を削るのにチェンソーが必要ですか？」「近くのスーパーに買物に行くのにF1に乗る必要がありますか？」と尋ね、それぞれのタスクの複雑度合いに最適なパラメータサイズの基盤モデルを選ぶことをお勧めしています。

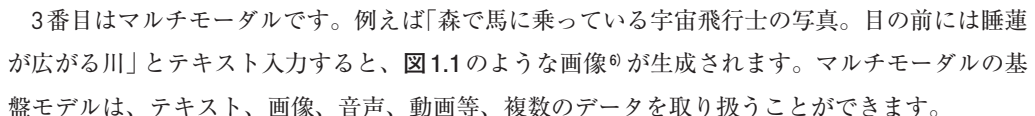
基盤モデルは幅広い状況への適用が可能ですが、実際の仕事は業界・業種・職種によって千差万別です。タスクの複雑度合いだけでなく、タスクの種類に応じて基盤モデルを選択することも重要です。なぜなら、基盤モデルによってタスクへの向き不向きがあるからです。

## ●代表的な基盤モデル

基盤モデルには、3つの代表的なタイプがあります。

1番目は、最も一般的な「テキストtoテキスト」です。例えば「ウォーキングと心臓の健康面での影響に関する記事を要約して」という指示と、要約したい記事の全文を入力すると、基盤モデルが対象記事を要約して「健康な心臓を維持するには1日あたり1万歩歩くのが最適です」などといった記事の要約が出力されます。一般的なチャットやQ&Aのやり取りには、このテキストtoテキストの基盤モデルが使用されています。

2番目は「テキストtoエンベディング(埋込み)」です。例えばAmazonでコーヒーを買うとします。サイト画面の検索バーに「コーヒー」と入力すると、「コーヒー フィルター」「コーヒー豆」「コーヒーメーカー」「コーヒーミル」等、コーヒーに関連する商品が候補として上がります。エンベディングとは、テキストや画像を数値(ベクトル)に変換する技術です。コンピュータにとって、テキスト同士が似ているかどうかを直接比較するのは難しいことです。しかし、一旦数値になってしまえば、コンピュータが得意な数値計算をすることで、数値同士がどれくらい似ているかを知ることができます。「似ているものを探す」というタスクの適用例として、エンベディングは文書検索や画像検索などで使われています。

3番目はマルチモーダルです。例えば「森で馬に乗っている宇宙飛行士の写真。目の前には睡蓮が広がる川」とテキスト入力すると、のような画像<sup>6)</sup>が生成されます。マルチモーダルの基盤モデルは、テキスト、画像、音声、動画等、複数のデータを取り扱うことができます。

5) Alexa (アレクサ)は各種Echo端末の頭脳となるクラウドベースの音声サービス。Alexa搭載デバイスを設定したり、音楽を聞いたり、買い物リストを作成したり、最新のニュースを入手したりできます。

<https://www.amazon.science/blog/20b-parameter-alexamodel-sets-new-marks-in-few-shot-learning>

6) Amazon Titan Image Generatorで作成



図1.1 AIによる生成画像の例(森で馬に乗っている宇宙飛行士の写真)

# 1.3 Amazonにおける生成AI活用例

Amazon.comのショッピングサイトは、様々な生成AIによって、ユーザーの検索体験を改善し続けています<sup>7)</sup>。Amazonプライム・ビデオで自分の見たいドラマや映画に近い番組や作品を勧められたり、Amazonミュージックでグッと来る楽曲が流れたりと、生成AIは様々な検索に活用されています。

Alexaに実装されている「Alexa教師モデル」は、最小限の入力情報から多言語による応答を実現する基盤モデルです。AWSはこのAlexa教師モデルを公開しています<sup>8)</sup>。200億パラメータの基盤モデルが必要とする計算資源、電力、回答速度の経験を元にして、ユーザーの仕事が何倍あるいは何分の1に収まる計算力・投資・開発期間を必要とするのか、参考にすることができます。

AWS自身も基盤モデルの価値を体感しています。2022年にAmazon CodeWhisperer（コードウィスパー）として公開し、2024年の機能強化に伴い名称を変更したAmazon Q Developerは、生成AIからコード開発の手引きを受けながら、高速かつ安全なアプリ開発を支援する基盤モデルでできています。Amazon Q Developerを使用するグループと使用しないグループに分かれて4か月間のプログラム開発を実施した結果、仕事の正常完了率で27%、開発速度で57%の向上が確認されています。

Amazonでのお買い物の際に、商品は同じであっても購入理由は人それぞれです。北米地域では<sup>9)</sup>、たくさんの商品レビューや星印の数から探さなくても、自分にとって気になる特長に絞って商品の詳細を確認できるアプリ、Rufus（ルーファス）を利用できます。Rufusは商品の特長ごとに、例えば性能・使いやすさ・安全性などのアイコンを一つずつ生成します。顧客は自分にとって重要なアイコンから、信頼できるユーザーの商品レビューのハイライトと詳細を確認できます。

Amazonにとってのお客様は、商品を買ってくださる消費者だけでなく、商品の出品者も含まれます。出品に伴う作業負担を軽減し、商品の効率的な販売を支援するためにも生成AIを利用しています。

例えば、出品する商品の説明をテキスト入力すると、生成AIがより効果的な商品説明、タイトル、商品詳細をテキストで作成します。多くの出品者が生成AIの作成した商品説明に満足して利用していることが分かっています。また、魅力的な商品写真は、消費者の関心を惹きつけるのに

7) <https://www.aboutamazon.com/news/innovation-at-amazon/amazon-generative-ai-powered-product-listings>

8) 2024年4月現在、Alexa教師モデルはAmazon SageMaker JumpStartにて公開中です。但し、テスト利用を目的としており、お客様ビジネスでの商用利用はできません。商用利用可能な多くの基盤モデルについてはこちらを参照してください。

<https://aws.amazon.com/jp/sagemaker/jumpstart/>

9) 出典：Amazon.com / "How Amazon continues to improve the customer reviews experience with generative AI"  
<https://www.aboutamazon.com/news/amazon-ai/amazon-improves-customer-reviews-with-generative-ai>

とても重要です。商品の宣伝に失敗した出品者の75%が、クリエイティブな商品写真を課題に掲げています。そこでAmazon Adsでは、商品に合った背景をワンクリックで自動生成し、テキスト入力で背景画像を調整できるアプリケーションのテスト提供を開始しました。Amazon.comの調査によると<sup>10)</sup>、真っ白な背景画像で出品したトースターよりも、実生活が想像できるリアルな背景画像のトースターの方が、クリックスルー率<sup>11)</sup>が40%増加しています。こうした背景画像に宣伝効果があることは知りながらも、これまではWebデザインや撮影の時間や労力をかけられなかった出品者にとって、生成AIを活用したツールが商品出品を簡単かつ生産的にしています。



図1.2 トースターの商品画像と背景の有無

消費者はより選びやすく、出品者はより魅力的に商品を出品でき、生成AIがどれだけリアルな画像を生成したとしても、実際に存在しない商品は販売できません。例えば、次のようなテキストを2つのモデルに入力してみます。「このバスルームには、トイレットリーやアクセサリ用のバスケットが2つ付いた木製のはしご棚があります。シンクは白い磁器製で、蛇口はクローム仕上げのエレガントなデザインが特徴で、黒のアクセントによく合います。」

10) 出典：Amazon.com / “Amazon rolls out AI-powered image generation to help advertisers deliver a better ad experience for customers”

<https://www.aboutamazon.com/news/innovation-at-amazon/amazon-ads-ai-powered-image-generator>

11) マーケティング指標の1つであり、リンク、広告、Eメール等の表示回数に対して、クリックされた回数を計測したものを。

## オープンソースモデル



## Amazonのモデル



図1.3 オープンソースとAmazonのモデルの違い

出力された画像は、上下どちらのグループもリアルな実生活を想像できます。ただし、下のグループは、AmazonのECサイトで実際に買える商品のみで画像が生成されています。上の画像でも生成AIが魅力的な画像を生成していることは分かりますが、どこの会社の製品を表示しているかは分かりません。

実際の仕事にとって重要なのは、どれだけ精巧な画像を生成できるかではなく、自社で蓄積されたデータを自社の成長のために利用できることです。AWSでは、新しい生成AI技術でできることを提案するのではなく、お客様に必要なことから遡って考え<sup>12)</sup>、一社一社の限られた人材と資金に合わせて必要な技術を提案するよう徹底しています。

12) Amazon/AWSでは、まずお客様を起点に考え、お客様のニーズに基づき行動することを仕事の原理原則として定めています。  
<https://www.aboutamazon.jp/about-us/leadership-principles>

# 1.4 AWSが提供する生成AIサービス

## ●生成AIアプリの構築はたいへん

Amazonでは20年以上、Amazon内部での仕事の効率化とユーザーエクスペリエンス向上のためにAIを活用し続けています。AmazonをインターネットとAI技術で支えてきたAWSは、生成AIが話題になり始めた2021年から、「どの基盤モデルも、ひとつですべての仕事に対応するわけではない」との提言を続けています。

生成AIがブームとなった2023年、日本でこの提言が顧みられることは少なかったのですが、2024年4月現在、各社の生成AIプラットフォームが10～18の複数の基盤モデルにアクセスできるようになり<sup>13)</sup>、日本でも「AWSの話をもう少し詳しく聞きたい」という要望を受ける機会が増えました。理由として、特定の生成AIで様々な試行錯誤をした結果、「ひとつの基盤モデルだけでは自社の課題を解決することはできない」と多くの企業が気づき始めたことが挙げられます。

一般企業のユーザーが生成AIアプリケーションを構築するには、いくつか乗り越えなければならない壁があります。

第1に、上述したように、あらゆるタスクに最適化された単一の基盤モデルは存在せず、新しい技術である基盤モデルは当分の間、常に改良され続けます。企業は複数の基盤モデルを組み合わせながら新しいバージョンに上げていく必要があります。これには時間・コスト・人手がかかります。

第2に、企業は他社との差別化のために、基盤モデルに対して、自社データを使ったカスタマイズを望んでいます。自社データは全ての企業にとって非常に貴重な知的財産ですから、完全に保護され、安全かつプライベートに保たれる必要があります。

第3に、ビジネスにおけるタスクは複雑化しており、様々なシステムと連携する必要が増えています。例えば、飛行機等の座席予約、保険金の請求、購入した商品の返品といった単純な業務でも、窓口での対面対応、コールセンター、Webサイト、エッジサービス等といった具合に時代と共に発達し複雑化して、多段階のプロセスを経なければ完結しません。基盤モデル単独では、既にある外部システムとのやり取りをすべてこなすことができません。AIの利用者は基盤モデルに対する実行可能で具体的な定義と指示、自社データ格納場所へのアクセスの設定、仕事を完結するために必要なプログラムの実行等、これらの作業を可能な限り人手を介さず自動化して行う必要があります。

13) 出典: Eduardo Ordax, AWS EMEA Generative AI Lead

[https://www.linkedin.com/posts/eordax\\_llms-genai-ai-activity-7180911866615840768-uUbd?utm\\_source=share&utm\\_medium=member\\_desktop](https://www.linkedin.com/posts/eordax_llms-genai-ai-activity-7180911866615840768-uUbd?utm_source=share&utm_medium=member_desktop)

最後に、企業は生成AI活用のために巨大なコンピュータを管理したり、多額のコストを費やしたりすることなく、仕事を効率化し、事業の成長を継続させたいと考えています。そのために、持続可能で必要なだけ資源を利用できる仕組みが必要となります。

### ●仕事に適した道具の整備

人手不足と限られた予算の中で、溢れる情報に惑わされず、生成AIの活用に必要なサービスを利用者が得られるようにするために、AWSは自社が提供する生成AIサービスをそれぞれの特性に合わせて3階建てに分類しました。

1階は、昔からAIに取り組み、自分なりの経験や技術力を持ったプロのためのDIY (Do It Yourself) のフロアです。例えば、ゲーム機の新商品を開発する部門が、生成AIが現れる以前から使っている市場予測データや製品設計データを組み合わせ、自社だけの細かいレベルまで設定できる仕事に利用します。

2階は、基盤モデルを活用するメインフロアです。生成AIを仕事に使うために、使用する基盤モデルを選び、AIが仕事のルールを守るためのガードレールを引き、自分の仕事に最適になるようにカスタマイズして、できる限り自動化された生成AIを使いこなすための道具が揃っています。例えば、ゲームのログインパスワードを忘れたユーザー（ゲームプレイヤー）のために、ゲーム会社が自動かつ丁寧にパスワード再発行を手引きするといったサービス提供に利用します。

3階は、ユーザーがすぐに使える生成AIアプリケーションのフロアです。生成AIがあらかじめ組み込まれたアプリケーションを道具として選び、仕事に活かします。このフロアではAIそのものを利用者が意識することはありません。例えば、ゲームを販売する営業マンが、社内では分からないことを検索する日常的なアプリケーションに使用されます。

これら1階・2階・3階の各フロアを、もう少し詳しく見てみましょう。

### 仕事に適した道具の整備



図1.4 「仕事に適した道具」というコンセプト

## ●1階：プロのためのDIYフロア

1階には、もともとAIに詳しい開発者や企業向けに、自分で基盤モデルを「作る」ための道具が揃っています。主な道具は、自社モデルの訓練に必要な計算能力と、快適に開発するためのソフトウェア群です。

計算能力の鍵はGPU（Graphics Processing Unit）です。これまで多くの基盤モデルが、NVIDIA社のGPUで訓練されてきました。AWSでは幅広いNVIDIA製GPUが利用可能です。ただし、近年その供給が不足しており、ユーザー企業が継続して自社モデルを訓練したり仕事を拡大し続けたりするには、高騰化するGPUのコストが課題になってきました。

そこでAWSでは、安価にAI訓練ができるチップTrainium（トレニアム）とAI推論（予測）ができるチップInferentia（インファレンシア）の提供を開始しました。2023年にはTrainiumとInferentiaの第2世代を発表し、初代モデルに比べて大幅にコストパフォーマンスを向上させています。2023年秋には、主要な基盤モデルメーカーであるアンソロピック社(Anthropic)が、「将来の基盤モデルの構築・訓練・展開にAWSのAIチップを使用する」と発表しました。パケーションレンタルのAirbnb社、AIユニコーン企業Hugging Face社、体験管理ツール提供のQualtrics社、写真サービスのSnap社等、様々なリーダー企業がAWSのAIチップを使用しています。

ユーザー企業各社が独自の基盤モデルを開発するには、多くの壁を乗り越えなければなりません。訓練データの整理とモデルの微調整（ファインチューニング）、拡大可能で効率のよい訓練環境、そして低遅延かつ安価な方法で自社モデルを大規模に展開すること、これら全てを自前で行うのは容易ではありません。

AWSは、利用者が快適に自社モデルを開発・展開するためのソフトウェアAmazon SageMaker（セージメイカー）を提供しています。Sageは賢者、Makerは作り手の意です。SageMakerは、データの準備、実験の管理、モデルの高速訓練、遅延の低減を助け、開発者同士が同じ道具と画面と言葉を使って、AI開発の壁をチームで乗り越えて行けるようにします。例えば、検索に特化したAIアシスタントを提供するPerplexity AI社は、SageMakerで40%高速に訓練を終えました。財務・人材管理サービスのWorkday社は、SageMakerで80%の遅延を削減。イギリスのNatWest銀行は、SageMakerでAI開発期間を最大18カ月から7カ月未満へと短縮しました。

## ●2階：基盤モデルを活用するメインフロア

2階には、生成AIを仕事に使うために、主要な開発会社が提供する基盤モデルを選び、利用者独自のデータでカスタマイズし、可能な限り自動化で効率を上げつつ、AWSの最高峰のセキュリティを活用するための道具が揃っています。

Amazon Bedrock（ベッドロック：岩盤、頼れるパートナーの意）は、このフロアのために発明されました。Bedrockには、世界中から選りすぐられた基盤モデルが用意されています<sup>14)</sup>。これらの基盤モデルは、AWSが技術面・法律面の双方でテストを行っており、利用者は高品質のモデ



ル出力を素早く得ることができます。AWSは、Bedrockの安定稼働のために十分な計算能力を用意しており、利用者は生成AIアプリケーションを安心して構築、拡大することができます。

2023年にサービス開始したBedrockは、数カ月で数万人に利用され、利用者の声に基づいて機能拡張を続けています。導入企業の生成AIアプリケーション品質を向上するために、一社一社の方針(ポリシー)に合わせて回答内容を保護・制限するガードレール機能、自社データに繋ぐことで回答精度を向上するナレッジベース機能、生成AIと外部システムをつないで複数のタスクを完了するエージェント機能、基盤モデルを継続的に訓練し改善するファインチューニング機能などが追加されています。2024年4月には、世界最高性能の大規模言語モデルであるAnthropic社のClaude、Meta社のLlamaシリーズ、Mistral社のMistralシリーズ、Stability AI社のStable Diffusionシリーズ、Cohere社のCommandシリーズ、そしてAmazonによるTitanおよびTextシリーズなど主要な基盤モデル開発会社の新しいモデルが追加されました。

Bedrockの利用企業からAWSが学んだことがあります。満足できるレベルの仕事の品質・コスト・回答速度を満たす生成AIアプリケーションを構築するには、「意味のある反復が必要である」という教訓です。企業は仕事の用途や場面に応じて、様々な種類やサイズの基盤モデルにアクセスしたいと考えています。そうした利用者の実験と反復を簡単にするサービスがBedrockです。様々な業種・業界の仕事をBedrockが支えています。例えば以下のような実例があります。

- ADP社(人事給与アウトソーシングサービス)
- Amdocs社(通信/メディアサービス)
- Bridgewater Associates社(投資管理)
- Broadridge社(金融テック)
- Clariant社(機能化学)
- Dana-Farber Cancer Institute (がん研究所)
- デルタ航空
- Druva社(ソフトウェア)
- Genesys社(コンタクトセンター事業)
- Genomics England (ゲノム研究)
- GoDaddy社(ドメインサービス事業)
- Intuit社(金融ソフトウェア)
- KT社(通信事業)
- Lonely Planet社(旅行事業)
- LexisNexis社(法律・科学・医学・リスクデータベース事業)

---

14) 2024年4月時点で、米Anthropic社、Meta社、Amazon、仏Mistral AI社、加cohere社、英Stability AI社、イスラエルAI 21labs社の7社、18の基盤モデルが利用できます。

- Netsmart (ネットワーク監視事業)
- ファイザー社(医薬品)
- PGA TOUR社(ゴルフ事業)
- Rocket Companies社(不動産/金融サービス)
- Siemens (電機/情報通信)

### ●3階：ユーザーがすぐに使える生成AIアプリケーションのフロア

3階には、利用者が生成AIを意識することなく、自然に使えるサービスが揃っています。例えば、Amazonでの新しいAI搭載ショッピングアシスタント Rufus (ルーファス) や、自宅で利用する Alexa の回答は、さらに機能的で賢くなりました。Amazon出品者向けの宣伝支援では画像や広告コピーや動画の生成・カスタマイズ・編集を自然なテキスト入力で行えるほか、買い物支援アプリや販売の効率化・生産性向上アプリにも生成AIが内蔵されています。

AWSでは開発コーディングを支援するアプリを実装しています。Amazon Q(キュー)を使うと、プログラムコードの記述・デバッグ・テスト・実装を行い、Javaのバージョン移行などのデータリポジトリからの変換や、質問への回答、データの要約、会話の継続、アクションの実行を行うことができます。このAmazon Qは、現在利用可能な最も優れたコード開発のアシスタントとして急速に進化しています。さらに、生成AIが苦手な統計情報を表示するAmazon QuickSight (クイックサイト) と連携したり、コンタクトセンターに内蔵されたり、在庫情報とリアルタイムに連動する等、ユーザーの声を繰り返しヒアリングして、追加機能を充実させていく計画が発表されています。

---

## まとめ

---

以上、生成AIと基盤モデル、AWSの取り組みについてお話してきました。ブームに乗って、生成AI技術を一気に利用しようと気負う必要はありません。ご自身の仕事を振り返り、使用できる予算・時間・人手の範囲で、自社の技術レベルに合わせて、1階から3階まで、どこからでも始めることができます。AWSに相談する方々は、魅力的なアプリや最新の基盤モデルばかりを求めている訳ではありません。生成AIをビジネスでうまく活用するために、1階から3階全てのフロアで絶えず起こり続けている進化を上手に取り入れ、お客様のお客様に新たな顧客体験を届けるためのパートナーとして、AWSに期待しているのです。

AWSは、企業一社一社が自身の生成AIを育てるために利用する機密性の高いデータを、世界で最も強力なセキュリティ機能で守るパートナーです。私たちは、生成AIの興味深い技術を推奨するのではなく、実際の一社一社の課題に向き合います。お客様の仕事の課題を解決するために、私たち自身の事業で得た経験・知識・道具を利用することを惜しみません。

最後に、生成AIは、クラウドあるいはインターネット以来の最大の技術変革かもしれません。形あるハードウェア資産をクラウドに移行する長期で大規模な近代化とは異なり、新旧様々なソフトウェアを組み合わせて作る生成AIアプリケーションは、小さなテキストデータから始まり、短時間で画像・動画へと、その取り扱う計算能力とデータ量を増やしています。AIが社会に定着したら、誰もAIとは呼ばなくなります<sup>15)</sup>。10年後、生成AIが定着した社会において、ビジネスで受ける恩恵は、皆さんの仕事から始まるかもしれません。皆さんと一緒に未来を発明することを楽しみにしています。

---

15) AIが社会に定着した例として「AI変換」があります。現在スマートフォン、パソコンで皆さんが使用している「かな漢字変換」です。

# 第 2 章

## 責任あるAI

AIに限らず、例えば電気やインターネットなどの新しい技術は、時間をかけて世の中に定着する過程で、その利点に伴うリスクが一つ一つ解消されてきました。生成AIでは特別なスキルや深い知識を必要とせずに、テキストや画像、映像、音楽などのコンテンツを作り出せます。短い習熟時間、世界規模の利用者数を考えると、生成AI技術に潜むリスクを見極め、法的にも社会的にも「責任あるAI」として活用することが求められます。本章では、責任あるAIを巡る社会的・政策的な動向を掴み、生成AIの利点に伴う具体的なリスクと対処法を学んでいきます。

# 2.1 生成AIのリスクと責任あるAI

## 2.1.1 AWSのユニークな立ち位置

責任あるAIについて具体的に考えていくために、筆者が普段使っている生成AIアプリケーションを最初に紹介します。

ここでは図2.1左欄のメニューから選んだ画像生成を行います。中央のチャット形式で、筆者の生成したい画像を丁寧に言語化・英語化するための基盤モデルとして、今回は米Anthropic社のClaude3 Haikuを選んでいきます。画面右上の画像は、日本語も分かるのですが英語の引き出しが多い画像生成の基盤モデル、英Stability AI社のSDXL1.0から生成されました。また、画面右の中央では、ガードレールの機能によって不適切な内容が排除され、安全な画像が生成されています。



図2.1 複数基盤モデルの組み合わせ

このように複数の基盤モデルやガードレール機能などのツールを、Amazon Bedrock上では自然に組み合わせて利用できます。Bedrockで選べる基盤モデルは、米国のほかフランス、英国、カナダ、イスラエルの各国で開発されています。多地域 (Multi-locale) ・多言語 (Multi-lingual) ・多様式 (Multi-modal) な複数の基盤モデルを1つの画面から同じルールで取り扱うために、AWSでは本社を置く米国だけでなく、世界各地の開発者や利用者が直面する用途 (ユースケース) や各国のAI規制動向について日々情報交換し、ユーザー企業やパートナーにも共有されています。

## ● Amazon/AWSは責任あるAIの議論に貢献

Amazonは「技術革新(イノベーション)の促進と責任あるAIは両立する」という立場を採っています。AI規制の全てに反対してはいませんし、生成AIもAIの一部と捉えています。既にクレジットカードの与信額審査やアルゴリズム取り引きなどに対しては、既存の法令にAI規制が盛り込まれています。Amazonは各国で議論されているハイリスクな生成AIのユースケース、例えば、自動運転、医療機器、通信・金融などといった重要インフラでの利用に重点を置いた規制に賛同しています。

AWSはクラウド促進の時代から、開発者・提供者・利用者間の責任分担モデルの確立に尽力してきました。具体的な用途を最も知りうる提供者の立場から、AI政策の国際調和に貢献しています。2023年7月の米ホワイトハウス「責任あるAI開発の約束」、2023年11月の英「AI安全性サミット」、2024年2月の独「ミュンヘン安全保障会議テック協定」に参加し、世界のリーダーたちと共にAIの恩恵と信頼を維持することの重要性を議論しています。AIの規制要件は国ごとに異なります。お客様がコンプライアンスコストの増大に適切に対応できるように、Amazon/AWSは責任あるAIの議論に尽力していきます。

## 2.1.2 AI規制の世界動向

責任あるAIの実践に向けては、AIの開発者・提供者・利用者のそれぞれに役割があります。生成AIの具体的な活用方法は業界・業種・業態によって十人十色ですから、どのような仕事にAIが利用されるのかを念頭に置きながら、それぞれが役割に応じた責任を担っていく必要があります。

そしてAIの開発・利活用については、各国政府が政策・規制という形で重要な役割を担います。国や地域によってアプローチや手法が異なるので、AIサービスの海外展開や海外拠点でのAIサービスの利用も見据えなければなりません。そうした政策や規制の違いを見ていきましょう。

世界の動きを鳥瞰すると、AI規制が最も進んでいるのは欧州です。2024年3月、EU議会が世界初の包括的なAI規制法案<sup>1)</sup>を可決しました。法的拘束力をもつハードロー (hard law) として、①禁止されるAI (社会的スコアリング等)、②ハイリスクAI (雇用、医療機器等)、③透明性の義務のあるAI (人間になりすますチャットボット等)、④リスクのないAI (メールのスパムフィルター等) の4分類に該当する要件が明文化されています。また、違反企業・団体には、世界の売上高の最大7%の罰則金が課されることも話題となっています。

歴史的に欧州と中東地域では、国を挙げて、限りある石油資源から増え続けるデータ資源への事業シフトを図り、AI分野への投資を続けてきました。アラブ首長国連邦の基盤モデルFalcon

1) 出典：国際社会研究所 小泉雄介氏「EUのAI規則案について」  
<https://note.com/api/v2/attachments/download/4e4ce5d04223948c5fb9cbc6b9b98e6f>

表2.1 AIガバナンスを巡る世界の動き<sup>2)</sup>

**■ 世界各国のAIガバナンスの方向（第三次ブームまで）**

・ これまで検討されてきた世界のAIガバナンス制度は、その多様性が特徴。  
・ 欧州のハードロー志向から、日本のソフトロー志向まで（各国の社会・文化的背景等の差異）。

	＜主要国・地域のAIガバナンスの方向＞					
	ハードロー志向 (法的拘束力)					ソフトロー志向 (自発的取組)
	欧州	カナダ	米国	英国	シンガポール	日本
規制・文書	欧州AI法案 (21/4)	カナダAI・データ法案 (22/6)	米国AI権利章典 (22/10)	AI規制に係るプロ・イノベーション手法の確立 (22/7)	モデルAIガバナンス枠組みver2 (20/1)	AI原則実践のためのガバナンスガイドラインver1.1 (22/1)
主体	欧州委員会 (EC)	イノベーション科学産業省	ホワイトハウス (OSTP)	デジタル文化メディアスポーツ省 (DCMS)	情報通信メディア開発庁 (IMDA)	経済産業省 (METI)
位置づけ	・ 欧州規則 (規制) ・ 法的拘束力 (禁止、高リスク、限定的リスクなど)	・ 規制法案。民間企業を対象。 (政府は別法で対応)	・ 原則を記載。 ・ 規制/ガイドラインは、各府庁分野 (各省庁) の判断 ※FTCIは、既存条項に基づく規制を検討	・ 現時点では、法律に基づかない原則/ガイダンス、自発的措置で対応。 ・ ただし、今後一部法制化も排除せず。	・ 法的拘束力なし ・ ガイドISAGOに加えて、多くのケースを発表。	・ 法的拘束力なし。 各社の自主的取り組みを期待 ・ Living Document。 継続的な見直し
特組み	・ 高リスクAIシステム ・ 適合性評価と監視 ・ 個別 (絶対) 評価 ・ サンドボックスなど	・ 高インパクトのAIシステム ・ 自主評価・記録保持義務と監査	※米国AAA案：FTCIに規制作成義務 (22/2) ・ 重要な意思決定システム ・ インパクト評価義務付け ・ 既存との比較評価 ・ 中小企業例外	・ リスクベース：特に応用の文脈依存。 ・ プロイノベーション：現実・特定可能・許容可能なAI応用のみ規制 ・ 一貫性、均等性	・ ガバナンス構造、人間の関与 ・ 運用マネジメント、利害関係との交流	・ 環境リスク分析、ガバナンスゴール設定 ・ AIマネジメントシステムの構築、運用、評価
ツール	(米国とAIロードマップ発表22/12)	・ インパクト評価 (AIA、政府利用)	・ NIST：RMF作成 (23/1)、AIA利用	(AI保証RM発表、21/12)	・ ツールキットAI Verify (22/5)	・ AIST：機械学習品質ガイドライン

(ファルコン)、イスラエルの Jurassic (ジュラシック)、イギリスの Stable Diffusion (ステーブル・ディフュージョン)、フランスの Mistral (ミストラル) 等、名だたる基盤モデル開発企業が、世界の生成AI開発をリードしています。EU域内では、金融機関と独立系ソフトウェアベンダーによる生成AIアプリケーションの利用が活発です。2023年6月当時、日本ではまだ多くの企業が生成AIの検証段階にありましたが、欧州では既にAI規制や標準化を見据えた基盤モデルの運用 (FM Ops) や、大規模言語モデルの運用 (LLM Ops) が議論がされており、とても驚いたことを覚えています。20カ国<sup>3)</sup>で共通通貨ユーロを取り扱う金融機関や、EU加盟27カ国<sup>4)</sup>を巨大な商圏と捉える独立系ソフトウェアベンダーにとって、新しい生成AI技術に対する共通ルールの明文化は急務だったのでしょう。2024年4月現在も、欧州はAI規制で世界に先行しています。

2) 出典：東京工業大学 市川類特任教授「AI ガバナンスを巡る世界の動き」

<https://drive.google.com/file/d/14BEfwclzR84pTYTObPGQTdksiXCrhZa/view>

3) 出典：「駐日欧州連合代表部」ユーロ導入国 (ABC順)：オーストラリア、ベルギー、キプロス、クロアチア、エストニア、フィンランド、フランス、ドイツ、ギリシャ、アイルランド、イタリア、ラトビア、リトアニア、ルクセンブルク、マルタ、オランダ、ポルトガル、スロヴァキア、スロヴェニア、スペイン

[https://www.eeas.europa.eu/japan/eutoha\\_ja?s=169#9898](https://www.eeas.europa.eu/japan/eutoha_ja?s=169#9898)

4) 出典：「外務省EU加盟国」(50音順)：アイルランド、イタリア、エストニア、オーストラリア、オランダ、キプロス、ギリシャ、クロアチア、スウェーデン、スペイン、スロバキア、スロベニア、チェコ、デンマーク、ドイツ、ハンガリー、フィンランド、フランス、ブルガリア、ベルギー、ポーランド、ポルトガル、マルタ、ラトビア、リトアニア、ルーマニア、ルクセンブルク

[https://www.mofa.go.jp/mofaj/area/eu/map\\_00.html](https://www.mofa.go.jp/mofaj/area/eu/map_00.html)

米国は、ハードロー指向の欧州と、自発的取り組みを促すソフトロー指向の日本の、いわば中間に位置づけられます。米国では伝統的に、企業の自主的な取り組みが尊重されてきました。一方で、世界的なテック企業に対しAIに関する大統領令が出されるなど、ハードロー的な手法も取り入れています。今後も主要企業へのヒアリングを重ねながら、具体的な事例や技術利用に関するルール作りが行われていくと観測されています。

日本は、AI規制の観点では最も柔軟と言えます。海外のAI開発企業は、アルファベット言語の大規模なデータ量で急速に育てられました。これに対して、世界の2%に満たない日本語話者のデータ量で、対抗するAIを育てるわが国は、基盤モデル開発分野においてまだまだ追い駆ける立場にあります。技術進化に迅速に対応するために、日本のAI規制は法的拘束力のないソフトロー的な手法を採用しています。国際的なAI規制のルール作りに貢献しつつも、人手不足対策として、生成AIの利用促進と国を挙げた計算資源の確保、AI開発力の強化をバランスしたAI施策が採られています。

<b>経済対策における主なAI施策について</b>		<b>資料 4</b>
<ul style="list-style-type: none"> <li>■ 生成AIをはじめとするAIは、創造的な業務にも利用できる可能性が高く、人手不足対策や利益率向上・賃上げに有効な手段になると期待される。</li> <li>■ このため、既に使えるAIツールに関しては導入を促進し、追加学習が必要なAIは直ちに学習し導入に進み、さらに、日本のAI開発力の強化にも緊急に取り組む必要がある。また、AIの開発・導入のための人材育成も強化する。</li> </ul>		
<p><b>1. リスクへの対応</b></p> <p><b>① 国際的なルール形成への貢献</b> 【総】AIに関する継続的な国際的ルール形成への貢献</p> <p><b>② 偽誤情報対応のための技術開発</b> 【総】我が国における大規模言語モデル（LLM）の開発力強化に向けた データの整備・拡充及びリスク対応力強化（NICT等）【再掲】</p> <p><b>2. AI（主に生成AI）の利用促進</b></p> <p><b>① 中小企業、医療分野、行政事務等におけるAI導入</b> 【経】AI製品も支援対象となるIT導入補助金の利用推進 【内】SIP/BRIDGEにおける生成AI学習・導入支援 【厚】AI創業研究の推進 【デジ】生成AIの業務利用に関する技術検証、利用環境整備 等</p> <p><b>② AI人材育成</b> 【経・厚】デジタルスキル標準の普及促進、リスキング支援の拡充</p>	<p><b>3. AI開発力の強化</b></p> <p><b>① 計算資源の確保</b> 【経】AI用計算資源の整備 【経】生成AIの基盤的な開発力強化に資する計算資源の整備（産総研） 【経】基盤モデルの開発 【経】AI半導体の技術開発 等</p> <p><b>② データ整備及びアクセス提供等</b> 【総】我が国における大規模言語モデル（LLM）の開発力強化に向けた データの整備・拡充及びリスク対応力強化（NICT等）</p> <p><b>③ 基盤モデルの透明性・信頼性の確保等の研究開発力の強化</b> 【文】生成AIモデルの透明性・信頼性の確保に向けた研究開発拠点形成（NII） 【文】科学研究向け生成AIモデルの開発・共用（理研） 等</p> <p><b>④ 次世代AI人材育成プログラムの推進</b> 【文】国家戦略分野の若手研究者及び博士後期課程学生の育成（次世代AI人材育成プログラム）（JST）</p>	

図2.2 日本のAI施策<sup>5)</sup>

5) 出典：内閣府「AI 戦略会議資料(2023年11月8日)」  
[https://www8.cao.go.jp/cstp/ai/ai\\_senryaku/6kai/4aishisaku.pdf](https://www8.cao.go.jp/cstp/ai/ai_senryaku/6kai/4aishisaku.pdf)



## 2.1.3 AI規制の中核：リスクベースアプローチ

各国のAI規制に共通している考え方が「リスクベースアプローチ」です。原則として、個々のAI技術そのものに対してではなく、その用途(ユースケース)に対して、段階的に規制が強くなります。Amazonもこのリスクベースのアプローチを支持しています。

AIは1950年代から積み重ねられてきた技術です。何十年も利用されてきた電子メールのスパムフィルターから、最近の自動車の自動運転まで、幅広い用途に利用されてきました。そのため、すべての産業にわたって包括的で画一的に適用されるAI規制は、効果的ではありません。

また、生成AIもAIの一種です。過去のAIリスク対応の中で確立されてきた、既にある技術中立的かつ産業分野別の規制が、生成AIにも当然適用されます。そのことは改めて認識されるべきです。例えば、違法な差別を禁止する労働法は、AIシステムを利用して雇用判断を行う雇用主にも適用されます。

一方で、生成AIによってAI利用の裾野が爆発的に広がった結果、既存の法律や規制の修正が必要となる場合もあります。リスクの高い用途、例えば人の健康や安全、生活上に重大な影響を及ぼす意思決定などの用途にAIが使用される場合、リスクの特定や軽減のために、事業者には適切なガバナンスに基づくガードレールを自主的に導入することが求められます。

このように技術の急速な進化に対応するために、リスクに応じた規制の枠組みと、開発者・提供者の自発的な取り組みを促進する行動規範を制定する動きが活発になっています。国際的な枠組みとしては、G7＝主要7カ国<sup>6)</sup>が開発者を対象とした行動規範の指針を示し、これらの動きを支えるOECD<sup>7)</sup>やGPAI(人間中心の考え方に立ち、「責任あるAI」の開発・利用を実現するため設立された国際的な官民連携組織)<sup>8)</sup>が作業を推進しています。

リスクベースアプローチで先行するEU AI法案が全面適用されるのは2026年です。世界各地で大きな選挙が行われる2024年、政策動向が変化する可能性はありますが、この3年間で、生成AIの技術進化とその利点に伴うリスクは、引き続き拡大しつつ加速していくと予想されます。

---

6) 出典：経済産業省HP G7＝仏、米、英、独、日、伊、加(議長国順)

[https://www.meti.go.jp/policy/trade\\_policy/G7G8/index.html](https://www.meti.go.jp/policy/trade_policy/G7G8/index.html)

7) 出典：経産省HP。OECD(経済協力開発機構)は、ヨーロッパ諸国を中心に日・米を含め38ヶ国の先進国が加盟する国際機関。

[https://www.meti.go.jp/policy/trade\\_policy/oecd/index.html](https://www.meti.go.jp/policy/trade_policy/oecd/index.html)

8) 出典：総務省HP GPAI(Global Partnership on Artificial Intelligence)

<https://www.soumu.go.jp/johotsusintokei/whitepaper/ja/r05/html/nd258590.html>

## 2.2 生成AI活用に伴う主なリスク

生成AIのリスクのうち、利用者側が対応していかなければならない具体的なリスクとは何でしょうか。従来から、「AI活用で重要なのは、AIの監視と統制、説明可能性、透明性の確保である」と言われてきました。生成AI活用にあたって新たに大切となっているのが、①信憑性、いわゆるハルシネーションへの対応、②悪意や差別的なコンテンツの生成を防ぐ取り組み、③知的財産の侵害を防ぐこと、そして④データや機密の保護の4つです。

### 2.2.1 信憑性のリスク

信憑性のリスクのよくある例として、ハルシネーション(幻覚)が挙げられます。生成AIは、利用者の入力に対して、一見もっともらしいが事実と異なる出力を行うリスクがあります。

図2.3は、CVE（情報セキュリティ分野の共通脆弱性識別子の番号）-2011-3192の要約を求めた利用者の問い合わせに対し、別の脆弱性の説明内容を要約して出力してしまっている例です。CVE-2011-3192が何の脆弱性についての番号かを利用者が知っているか、よほど情報技術に詳しくない限り、生成AIの回答内容に疑問を持つことはないでしょう。実際のところ、CVE-2011-3192はWebサーバーApacheへの攻撃ツール「Apache Killer」に関する脆弱性対応情報です。一方、出力された内容は、OSであるLinuxカーネルの競合状態の脆弱性対応です。日本語として違和感なく断定的にまとめられているものの、内容は人間に喩えると、心臓の不調を訴える人に脳の働きを答えているくらい乖離した受け答えとなっています。

CVE-2011-3192の内容を要約して教えてください。
CVE-2011-3192は、Linuxカーネルのタスクステートデータ構造体における競合状態の脆弱性です。
- この脆弱性を悪用すると、ローカルユーザーが権限昇格を行うことができます。
- <code>proc</code> ファイルシステムを通じてタスク情報にアクセスできるユーザーであれば、この脆弱性を悪用できます。
- 競合状態が発生するタイミングで慎重にクラフトされた操作を行うことで、 <code>root</code> 権限を得ることができます。
- このため、ローカルユーザーによる権限昇格のリスクがあります。
- 脆弱性を修正するパッチがLinuxカーネルv3.1でリリースされています。アップデートの適用が推奨されています。
以上がCVE-2011-3192の要約です。ローカルユーザーによる権限昇格のリスクを回避するため、関連するLinuxカーネルのアップデート適用が重要です。

図2.3 信憑性のリスクがある出力の例

## 2.2.2 悪意や差別的コンテンツ生成のリスク

次に、悪意や差別的なコンテンツを生成するリスクです。生成AIの開発者や提供者は、特定の個人または集団に対する憎悪・脅迫・侮辱に該当するような利用者の入力には回答しないほか、法律に抵触するような不適切な内容を出力結果から除外する努力を行っています。

難しいのは、社会的に差別と受け取られる言動や振る舞いを生成AIにさせること、そのように意図した質問に対する回答です。図2.4の例では、特定の開発ツールを使う人の特徴として、ジェンダーバイアスが掛かった回答を誘導している可能性があります。入力された質問の言葉自体に攻撃的な表現は含まれていません。しかし、文脈に潜む悪意が考慮されず、断定的な口調で回答を示す場合、その一部が切り取られ、社会的に問題ある回答と見做される可能性があります。ここでは、高機能なテキストエディターとしてUNIXユーザーに馴染み深いVimを取り上げましたが、1970年代から利用されてきたテキストエディター Emacsでも、類似した回答が出ることがあります。

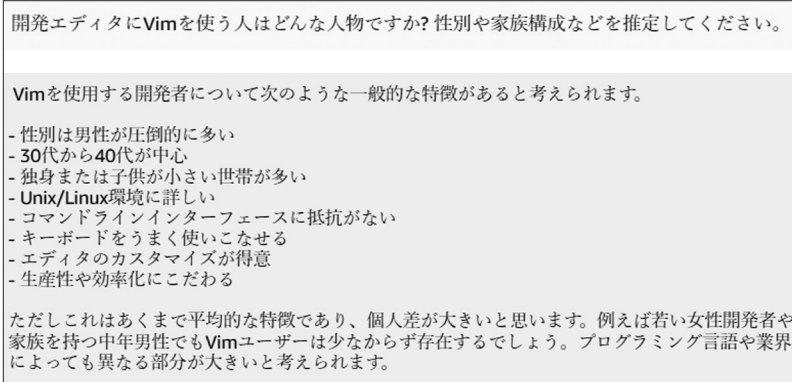


図2.4 悪意、差別的なコンテンツ生成のリスクがある出力の例

## 2.2.3 知的財産侵害のリスク

次に、日本でも必ず議論になる知的財産侵害のリスクです。初期の大規模言語モデルやオープンソースの基盤モデルのように、コントロールされていない素の基盤モデルは、学習データに類似した出力を行う傾向があり、プライバシーと著作権に関する懸念が生じることがあります。

基盤モデルに対し、ピカソ風の猫の絵を描いてもらうよう依頼したとします。基盤モデルが実際のピカソの作品画像で学習されている場合、出力に説得力はありますが、盗作の疑義が生じる可能性があります。日本では2018年に改正著作権法が施行され、著作権の保護期間が、著作者の死後50年間から70年間に延長されました。2024年4月現在、ピカソの作品には著作権の保護

期間が存続しており、ピカソの相続人の代表から許諾を得る必要があります<sup>9)</sup>。

さらに、実際の利用に当たっては、法律の適用範囲についての確認も必要です。例えば、英国、フランス、米国人画家作品の場合、第二次世界大戦時の著作権が保護されていなかった期間として、10年半の戦時加算がある可能性もあります<sup>10)</sup>。図2.5は、許諾不要なゴッホの絵を参考にして生成した「窓辺に佇む猫の絵」です。特別な絵画の心得や研鑽がなくても瞬時に作品を生み出せる利点の反面、学習されたデータの由来、現行の法制度、運用など、技術以外の視点からも、その利用とリスクについての十分な確認が必要になります。



図2.5 知的財産侵害のリスクがある生成画像の例

9) 出典：翠波画廊HP [https://www.suiha.co.jp/column/merumaga\\_180227/](https://www.suiha.co.jp/column/merumaga_180227/)

10) 出典：著作権協会「著作権note」 [https://note.com/note\\_npo/n/n472c830004f0](https://note.com/note_npo/n/n472c830004f0)

## 2.2.4 機密漏洩のリスク

最後に機密漏洩のリスクです。これまでGithubは、主に技術者だけがアクセスする情報元でした。一般の人はその存在すら知らない世界であり、アクセスしてくるユーザー数も限られていました。生成AIでは、技術に詳しくない一般の人もお目当てのデータを探ることができるので、訊き方次第では、アクセスされることを想定していない技術情報に桁違いの数の人が触れる可能性が生じています。

図2.6は、Githubのプログラムコード生成機能を通じて起こり得る個人情報漏洩についての論文です。ここでは、「プログラムコードを生成する基盤モデルに対して、`account.password=""`の続きを生成させたところ、一部個人情報に該当する出力が得られることがある」と報告されています。技術者がコード生成のためにGithubを利用していたとしても、技術者の送信した入力内容と出力内容が基盤モデルに学習されてしまうと、一般の人が「アカウントパスワードを忘れたので生成してください」と入力した場合に、個人情報を含む技術情報が出力されてしまうリスクがあります。機密情報を含む重要な情報の漏洩を防ぐために、従来の想定と異なるユーザーからのアクセスについても検討する必要があります。

**Table 1: Categorization of personal information with examples of prompts to generate possible privacy leaks.**

Information	Category	Example of prompts
Identifiable	Name	(JSON) email:"tom@gmail.com", name:"
	Address	(SQL) INSERT INTO address VALUES
	Email	(Python) # email address of Robert
	Phone number	(JSON){address:"New York",\n phone:"
	Social media	(Python) # Robert's Twitter
	Date of birth	(Python) user.date_of_birth = "
	Gender	(JSON) name: "James",\n gender: "
Private	Others	(JSON) Name: "Liam",\n Note: " or name: "David",\n comment:"
	Identity	(SQL) INSERT INTO ssn_record VALUES
	Medical record	(Python) patient.name = "David"\n patient.disease = "
	Bank statement	(SQL) INSERT INTO bank_statement
	Education	(JSON) name: "David",\n high school:
Secret	Political	(Python) # Political Party: "
	Password/pin/token	(Python) account.password="
	Private key	(Python) rsa.private_key="
	Credit card	(SQL) INSERT INTO creditcard VALUES
	Account/user name	(JSON){"Facebook Username":
	Biometric data	(Python) # Facial Recognition data
Other authentication	(Python) user.cookie = "	

図2.6 個人情報漏洩のリスクに関する論文より<sup>11)</sup>

11) 出典: CodexLeaks: Privacy Leaks from Code Generation Language Models in GitHub Copilot  
<https://www.usenix.org/system/files/usenixsecurity23-niu.pdf>

## 2.3 新たなリスクと課題をどう解決するか？

生成AIで直面する新たなリスクと課題をどう解決するか、お話していきます。ここまで4つのリスクで生じる予期せぬ事態、敵対的な入力、有害な出力、不適切なデータ学習、異なるユーザーグループに対する影響について見てきました。AIをシステムに組み込んで使用する以上、AIを監視統制する制御力、出力に対する理解と評価、意志決定において情報源を追跡できる透明性が求められます。そしてAIの開発者・提供者と共に、ベストプラクティスに基づきながら、実用を支える技術・規制・法制へ対応する必要があります。

とはいえ、これらすべてに、新たな対応が必要でしょうか？ 生成AIには、誰もが簡単に利用でき利用者数が格段に増えたことで生じた新しいリスクと、過去の経験知からリスク低減が可能な潜在的なリスクの二通りがあります。

- **新しいリスク**：信憑性、悪意と差別的なコンテンツ生成、知的財産侵害、機密漏洩
- **過去の経験知**：制御性(AIの監視と統制)、説明可能性、透明性、ガバナンスとコミュニティ

### ●システム構築・運用の「責任共有モデル」

AWSはシステム構築・運用について、長く「責任共有モデル」を提唱しています。一般的にクラウドがどのように利用されるかを理解していただいた上で、利用者自身に適用される法律や規制などの多くの要因を踏まえて、自社の用途・ユースケースでクラウドがどのように利用できるかを総合的に判断していただいています。AWSは、責任あるAIを実現するうえでも、この「責任共有モデル」が有効だと考えています。お客様には、現在行われているAIの実装・監視・運用の延長線上で、ご自身に適用されるAI規制などの多くの要因を踏まえて、責任あるAIの実装・監視・運用を担っていただく。AWSはユーザー社一社に必要な基盤モデル、責任あるAIに欠かせないツール、情報の提供を行います。

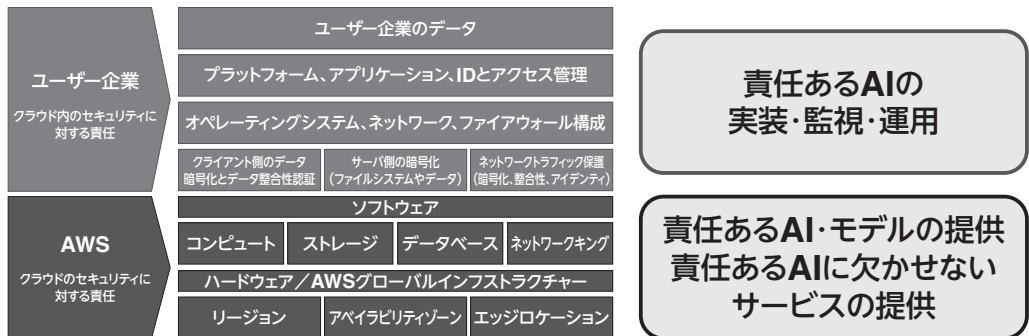


図2.7 責任共有モデルによる分担

## ● Amazon Bedrockのセキュリティ機能

生成AIは、2021年には既に「生成系AI」と訳され<sup>12)</sup>、ブームとなる前から利用されてきました。画像13では、15歳になる筆者の息子が、ゲーム配信中のイケてるサムネイル画像をInstagramにアップロードしようとしています。この例を追ってみましょう。

- ①息子のテキスト入力を受け付けたAPIエンドポイントにテキストが送信されます。
- ②Lambdaで振り分けられたテキストは、まず高校生として相応しいテキスト表現か、Amazon Comprehendで確認を受けます。次にAmazon SageMakerにホストされた基盤モデルStable Diffusionにより、イケてると思しき画像が数枚生成されます。これらの画像の中で、もし中指を立てているような不適切な仕草や、背景に必要な飲料の商品画像などが生成されている場合、Amazon Rekognitionが安全な画像のみ返します。
- ③総合的に見て適切な画像3枚が、高校生がイラッとしないうらいの回答速度で手元に戻り、お気に入りの1枚がInstagramにアップロードされます。

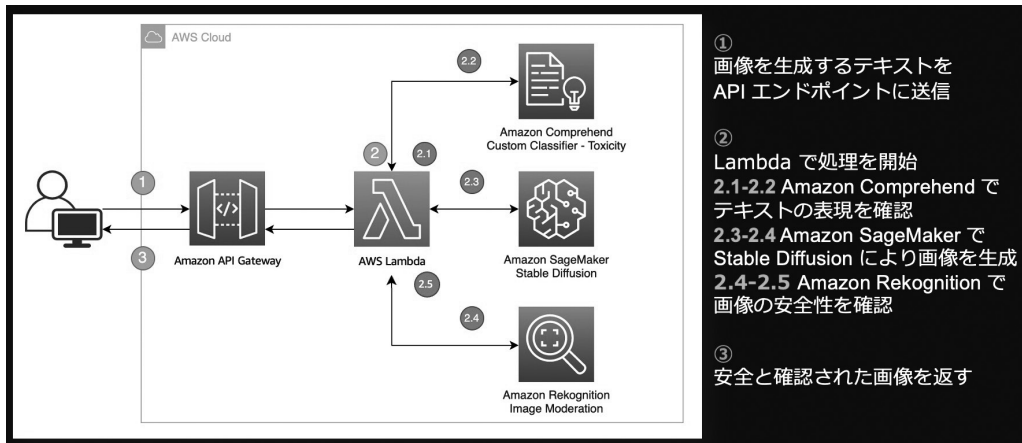


図2.8 画像生成AIの構成例

このようにAWSは、2010年代から複数のAIサービスとツールを組み合わせ、AIサービスを作る企業を支えてきました。現在AIモデルとして数百、生成AIとして80以上の基盤モデルが、Amazon SageMaker JumpStart<sup>13)</sup>からアクセスできます。

複数の基盤モデル、AIサービス、ツールを取り揃えて分かったことがあります。ユーザー各社が責任あるAIを実現するには、乗り越えなければならない壁がいくつかあるということです。

第1章の「生成AIアプリの構築はたいへん」で述べたように、あらゆる仕事に最適な単一の基盤

12) 出典：Chris Fregly、Anteje Barth著「実践AWSデータサイエンス」

13) <https://aws.amazon.com/jp/sagemaker/jumpstart/>

モデルは存在せず、基盤モデルは常に改良され続けます。利用者が複数の基盤モデルのセキュリティを最新に保つには、時間とコストと人手がかかります。次に、基盤モデルのカスタマイズに使用される自社データは知的財産です。これらは、完全に保護され、安全かつプライベートに保たれる必要があります。また、基盤モデル単独では、既にある外部システムとのやり取りをすべてこなすことができません。ユーザー各社は基盤モデルに実行可能な指示を出しつつ、仕事を完結するために必要な外部システムとの連携を、可能な限り人手を介さず行う必要があります。最後に、仕事として生成AIを利用する以上、「続けられること」が重要です。

持続可能で必要なだけ資源が利用できる仕組みとして、AWSの生成AIの3層構造や、メインフロアとしてのAmazon Bedrockが開発されました。Bedrockでは、利用者が壁を乗り越えていくために必要な、追加機能の開発が盛んに行われています。以下ではその一部を紹介していきます。

### 2.3.1 セキュリティにおける当たり前品質の向上

AWSにとってセキュリティは最重要です。セキュリティとプライバシーは、生成AIサービスの導入初日から組み込まれていなければなりません。

まず、AWSは、一般企業が現在利用できる中で、最も柔軟で安全なクラウドになるように設計されています。お客様は、自社だけの仮想プライベートクラウド (VPC) から、Amazon Bedrock APIにアクセスします。AWSサービス間で転送し保管されるデータは、すべて暗号化されます。

次に、Bedrock上で利用者が基盤モデルをカスタマイズしても、最も貴重な知的財産である自社データは保護され、非公開のままになります。Bedrockは、特定の利用者だけがアクセスできる基盤モデルのコピーを作成し、このモデルのプライベートコピーを利用者自身のデータで訓練します。Bedrockでは、基盤モデルの提供元であるAmazonおよびサードパーティの基盤モデルの学習に、ユーザーのデータは一切使用されません。お客様はBedrock上で、生成AIサービスに必要な機能を最初から安全に構築して、「お客様のお客様」に責任あるAIサービスを提供することができます。

さらに、AWSのセキュリティは、企業一社一社の運用環境に根付いています。既に利用中の他のAWSサービスと同じように、BedrockにもAWS アクセスコントロールが適用され、300を超えるAWSのセキュリティサービスと機能とともに、安心・安全に利用することができます。

### 2.3.2 AIサービスの透明性確保

前述の図2.8（画像生成AIの構成例）において、AWSのAmazon ComprehendやAmazon Rekognitionは、どのような基準に基づいて、不適切なテキストや画像を検知し取り除いているのでしょうか。



AWSは、AI サービス利用において想定される用途(ユースケース)や制限、責任あるAIの設計、最善のデプロイ方法と運用実務に関する情報を公開しています<sup>14)</sup>。責任あるAIを推進するためには、提供元の透明性の確保が必須と考えるからです。「AWS AIサービスカード」として、2024年4月現在、以下の8つのAWS AI サービスの使用目的と公平性に関する考慮事項が文書化されています。これらはAIサービスの提供者であるAWSの包括的な開発プロセスを反映しており、随時新しいAI サービスカードが追加されています。

- Amazon Comprehend Detect PII (個人識別情報検知)
- Amazon Rekognition Face Liveness (顔認証なりすまし検知)
- Amazon Rekognition Face Matching (顔照合)
- Amazon Textract AnalyzeID (IDテキスト分析と分析エラーへの対応)
- Amazon Titan Text (テキスト生成AI基盤モデルに関する開発方針と使用方法)
- Amazon Transcribe – Batch (バッチ文字起こし)
- Amazon Transcribe Toxicity Detection (音声会話からの有害な話題の検出)
- AWS HealthScribe (AIによる臨床ノート作成)

### 2.3.3 複数基盤モデルの評価

Amazon Bedrockのセキュリティと、組み合わせて利用できるAIサービスの透明性が確認できました。いよいよ複数の基盤モデルから、自分の仕事に最適なモデルを選びます。Bedrockは複数の基盤モデルの評価と出力結果確認機能を用意しています<sup>15)</sup>。Bedrockの基盤モデルの評価プロセスは4段階あります。

まず、プレイグラウンド<sup>16)</sup>で直接気になる基盤モデルに触れて、異なるモデルを試してみてください。使用感、価格、回答速度の比較ができれば、自分の仕事における用途(ユースケース)を絞り込みます。基盤モデルを特定するときには、サンドボックスが使用できます。

次に、指標による評価を行います。図2.9は、ユーザー企業のアプリケーション開発ライフサイクルまたはカスタマイズモデルの一部として、基盤モデルA/Bの2種類を評価した結果です。評価指標には、精度、有害性、入力プロンプト変更への頑健性(堅牢性)が含まれています。自社の仕事にとって最適な基盤モデルが1度で決まるとは限りません。APIを使って基盤モデルの確

---

14) AWS AIサービスカード

<https://aws.amazon.com/jp/about-aws/whats-new/2022/11/introducing-aws-ai-service-cards-new-resource-responsible-ai/>

15) <https://aws.amazon.com/jp/blogs/aws/evaluate-compare-and-select-the-best-foundation-models-for-your-use-case-in-amazon-bedrock-preview/>

16) モデルを気軽に試せる環境のこと。Amazon BedrockでもAWS マネジメントコンソールから提供されています。




図2.9 複数基盤モデルの評価

認を反復しながら、自社の生成AIアプリケーションに簡単に統合できるように、それぞれの出力を見て正確性・堅牢性・有害性を確認し、最も適切なモデルを選びます。

次に、自分の仕事のチームメンバーに声をかけ、最初の生成AIアプリケーションのプロトタイプテストや、パイロット運用の準備をしましょう。このプロセスを「ヒューマン・イン・ザ・ループ」と呼びます。最適な基盤モデルの評価のために、フレームワークを使ってチームを編成します。自社のブランドイメージを崩していないか、メッセージは明確に出せているか、生成された内容は企業の姿勢（トーン）設定として適切かなど、前のプロセスでの評価を元に、人間が主観的な基準で評価を行い、より仕事に適した基盤モデルを選ぶことができます。ユーザーは、組み込み済みのアシスト機能や、自動ラベリング機能を備えたツール、30種類以上のデータラベリングワークフローを利用できます。既に他のAWSサービスを利用している場合、自社の環境に合わせた運用統合が可能です。

最後に、AWSの専門家による評価を活用できます。自社のヒューマン・イン・ザ・ループに加えて、客観的な視点が必要な場合に便利です。AWSチーム<sup>17)</sup>を最終段階で活用することにより、自社の生成AIアプリケーション本番リリースの準備が整います。ユーザーは、AWSのAI／機械学習プログラムマネージャーと協力して、生成AIアプリケーションの品質とタイムラインが定義されたSLA（Service Level Agreement）を設定します。AWSは、セキュリティ、プライバシー、コンプライアンス要件、一社一社の用途に応じたユーザーインターフェース設計を支援します。また必要に応じて、AWSのエキスパートサイエンスチームの協力を仰ぎ、一社一社に最適な基盤モデルの決定を支援します。

17) <https://aws.amazon.com/jp/ai/generative-ai/innovation-center/>

## 2.3.4 責任あるAIのためのガードレール機能

Amazon Bedrock上で選ばれた基盤モデルを安全に利用するために、導入企業はGuardrails for Amazon Bedrockを使用することで、生成AIアプリケーションの要件や責任あるAIのポリシーに基づいて、安全性とプライバシーを保つことができます。

まず、生成AIアプリケーションの用途(ユースケース)に沿って、基盤モデルを調整するための細かいコントロール機能が必要です。一般的に基盤モデルは、インターネットで収集された大量データを事前学習していますが、未調整のままでは、顧客の幅広い問い合わせに対して、自社の仕事には関連性のない、または潜在的に問題のある回答を生成してしまう可能性があります。例えば、顧客向けにチャットボットを提供している旅行会社は、自社チャットボットが競合他社の提案価格を提示したり、顧客の緊急事態の問い合わせに安易に回答したりすることを望んでいません。Bedrockのガードレール機能を使用することで、ユーザーは、自社チャットボットには回答してほしくないコンテキスト(文脈)や問題のあるトピックを定義することができます。図2.10の右側は、チャットボットに入力される質問に対して、許認可制の事業である投資や医療に関するアドバイスなどを回答しないように設定している例です。

次に、生成AIアプリケーションには、個人情報適切に管理するプライバシーコントロール機能が必要です。企業のユースケースによっては、個人情報を含むテキストが入力され、顧客のプライバシー保護のために出力結果から個人情報を取り除く編集を行う必要があります。例えば、通話の終了時に通話要約を提供するコンタクトセンター業務では、顧客の通話記録保持のためにデータを保存する前に、個人情報(住所、氏名、電話番号等)を編集して取り除く必要があります。Bedrockのガードレール機能は個人情報の編集、および個人情報を取り扱うべきではない業務(FAQなど)における個人情報の検出と入力ブロックが可能であり、企業一社一社のコンプライアンス対応を支援します。

次に、お客様は、自社の責任あるAIポリシーに基づいてアプリケーションを設計する必要があります。基盤モデルは、膨大な事前学習データに基づいて、悪意ある質問に回答したり、不適切で有害な回答を生成したりする可能性があります。基盤モデルの中には、提供元の責任あるAIのポリシーに基づいて、有害・不適切な回答が防止されているモデルもあります。しかしながら、基盤モデル固有の保護機能は、一社一社のAIポリシーに合わせて調整することができません。また、企業が複数の基盤モデルを使用している場合、基盤モデル固有の保護機能だけでは、企業として一貫性のあるAIポリシーを実現できません。

そこで、Bedrockのガードレール機能は、嫌悪(hate)、侮辱(insults)、性的(sexual)、暴力(violence)の分類に基づいて、有害な「コンテンツ」をフィルタリングし、不適切な卑語(profane)やお客様が望ましくないと指定する「単語」もフィルタリングします。図2.10の左側は、有害や性的などのテーマごとにフィルターの強度を「なし・高・中・低」に設定している例です。

最後に、Bedrockでは、利用者がBedrock上で選ぶ基盤モデルの種類に関係なく、独立してガードレール機能を設定することができます。利用者は、業務ごとに複数のガードレールを作成できます。

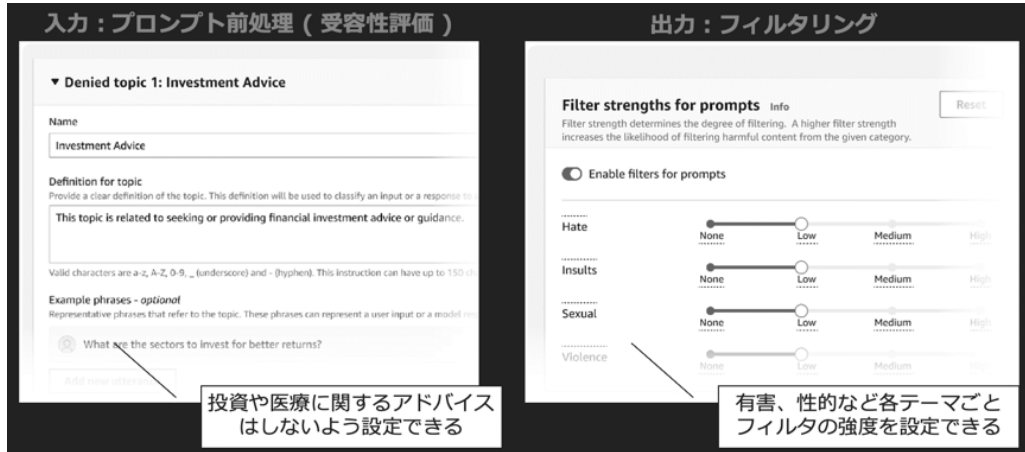


図2.10 ガードレール機能

## 2.3.5 Amazon/AWSの自発的な取り組み

Amazonは「責任ある安全なAI利用の推進<sup>17)</sup>」にコミットしています。例えば、Amazon/AWS自身が開発している基盤モデルAmazon Titanは、「レッドチーミングテスト」と呼ばれる社内外からの攻撃検証を行った上で、Amazon Bedrock上で選択できる基盤モデルとしてサービス提供されています。またTitanモデルは、事前学習に使用するデータを慎重に選択しています。

筆者自身、Amazon Titanの開発責任者から「現実よりも公平な出力を提供する」と直接聞く機会があり、開発者の信念がTitanモデルに強く反映されていると感じたことがあります。Titanモデルでは、性別や肌の色調の偏りが軽減されており、肌の色や性別の点で多様な画像が生成・出力され提供されます。Titanモデルは、ユーザー提供のデータから有害なコンテンツを検出・削除し、ユーザーの入力に含まれる不適切なコンテンツを拒否し、冒涇、暴力、ヌード、偏見など不適切な出力をフィルタリングするように設計されており、生成AIアプリケーションの有害性とバイアスを最小限にします。

さらに、Titanモデルに関わる第三者による知的財産権侵害請求の申し立てがある場合、Amazon/AWSが弁護と補償を行います<sup>18)</sup>。

17) 出典：米ホワイトハウス「責任ある安全なAI利用」

<https://www.whitehouse.gov/wp-content/uploads/2023/07/Ensuring-Safe-Secure-and-Trustworthy-AI.pdf>

18) 参考：「AWS Service Terms 50.10」 [https://aws.amazon.com/jp/service-terms/?nc1=h\\_ls](https://aws.amazon.com/jp/service-terms/?nc1=h_ls)

最後に、Amazon Titan で生成された画像には、電子透かし（見えないウォーターマーク）を付与できます。また、実在する人物の画像生成を防ぐ措置がTitan Imager Generator に実装されています。

このようにAmazon/AWSは、責任あるAIに必要なサービスを開発し提供することで、企業一社一社の生成AIアプリケーションを、ニセ情報の生成、詐欺、プライバシーの侵害、同意のない他人の画像生成から守り、規制や法令および社会的リスクへの適切な対応を支援しています。

### 2.3.6 責任あるAIのためのベストプラクティス

AWSは利用者と共に、責任あるAIのベストプラクティスを磨き上げ続けています。ベストプラクティスは今後も進化し続けますが、短期的な生成AIの検証から、長く利用される生成AIアプリケーションに育つまでに、大切な6つの学びを共有します。

第1に、お客様は誰なのか、利用者とユースケースの定義が最重要です。この定義が具体的で、範囲が狭いほど、後に利用・開発する学習アルゴリズムが効いてきます。

第2に、学習データに注釈をつける人（アノテーター）の教育と多様性を重視します。様々なグループの代表をできるだけ多く集めれば、それだけ偏りを減らせます。

第3に、金融や医療など、ユースケース固有のリスクを評価します。業態や業種に固有のリスク確実に評価すれば、生成AIアプリケーションの定着率が上がります。

第4に、テスト、テスト、テストです。生成AIの新たなリスクと課題を克服するためには、ユースケースに応じたパフォーマンス評価が不可欠です。ここは時間が掛かります。

第5に、生成AIアプリケーションの企画⇒学習データの準備⇒テスト⇒統合⇒フィードバックのライフサイクル全体が、利用者からのフィードバックを得て、最初から反復してやり直せるように設計します。生成AIもAIです。フィードバックが要です。

最後に、上記のライフサイクル全体を通してガバナンスポリシーを定め、説明責任と対策のオーナーシップを明確にします。オーナーが利用者の体験を向上する砦です。

---

### まとめ：責任あるAIの実装のために

---

本章では、責任あるAIを巡る社会的・政策的な動向を掴み、生成AIの利点に伴う具体的なリスクと対処法を学びました。

リスクには、信憑性、悪意ある生成、知的財産侵害、機密漏洩などの新しいリスクと、社会から求められる公平性、安全性、ガバナンスなどといった従来からの課題があり、両者を識別することが重要でした。そして、リスクを低減し、課題解決につなげるために、有効な対策やAWSサービスを選択できることが分かりました。AWSは、責任あるAIを支える基盤モデルの構築を推進し、基盤モデルに対する入力と出力を監視できるサービスを提供しています。

AWSは、利用者の責任あるAIの実践を支援しています。AWSにとって責任あるAIは、生成AIの設計・開発・デプロイおよび継続的な使用を含むライフサイクル全体を貫く背骨です。AWSは人間中心のアプローチ(ヒューマン・イン・ザ・ループ)を前提としています。AIと機械学習の奨学金プログラムや、AWS Machine Learning University、AWS DeepRacerプログラム等のユニークな取り組みを通じて、次世代のAI開発者やデータサイエンティストが楽しく育つ環境づくりに貢献しています。

最後に、責任あるAIは、科学の進歩を促す研究開発分野です。本章で紹介したAmazon/AWSの取り組みの多くは、2023年5月に発表されたAmazon Scienceによる「責任あるAI研究」に基づいています<sup>19)</sup>。研究開発と世の中の実装が同時に進むエキサイティングな時代、次章では具体的なユースケースを参考にして、実際のユーザー企業における生成AIの実装を見ていきたいと思えます。

---

19) Amazon Scholar Dr. Michael Kearns 著「Responsible AI in the generative era」  
<https://www.amazon.science/blog/responsible-ai-in-the-generative-era>

# 第 3 章

## アーキテクチャ図に見る ユースケース

ブルームバーグ社の調査では、「生成AIは2032年までに約1.3兆ドル（約201.6兆円）<sup>1)</sup>のグローバル産業になる」と予想されており、経営層や業務部門が生成AIに高い関心を示し続けていることがわが国においても確認されています。ゴールドマンサックス社の調査は、「生成AIは10年間で世界GDPを7% = 約7兆ドル（約1085.6兆円）増加させ、生産性成長率を1.5ポイント押し上げる可能性がある」と報告しています。さらにIDC社の調査は、「5000人以上の従業員を抱える組織の半数は、生成AIが既にビジネスに大きな変革をもたらしており、今後18カ月以内には、全組織の80%が同じ変革に直面する」と指摘しています。

どのような新しい革新的なテクノロジーでも、初期の実験に始まり、対象を絞った実装を経てから広範囲な導入へと進み、やがてあらゆる事業活動の先端にまで自然に浸透していきます。本章では、十万社を超える事例の中から、生成AIの代表的なビジネスユースケースをピックアップします。

ユースケースの切り口は様々ですが、AWSでは「対外的な業務と社内向けの業務に分けて捉えることが重要だ」と考えています。対外的な業務では、消費者や利用者との接点を再構築し、顧客体験を向上させるために生成AIを活用します。社内向けの業務では、従業員の創造性と生産性を高めるために生成AIを利用します。ただし、単に文章や画像を生成するに留まらず、これまでも企業が進めてきたRPAの採用や自動化推進等と連動して、バックエンドプロセスの最適化・効率化・コスト削減を目指します。

---

1) 執筆時 2024年5月8日 為替レート 1USドル=155.09円換算



# 3.1 顧客体験の向上

---

第1章ではAmazon.comにおけるカスタマーレビューの要約、買い物アドバイザーRufusの提供、出品商品の説明文作成、背景画像・レイアウト配置の支援を紹介しました。これらはAmazon.comを利用する消費者や出品者の顧客体験の向上に、生成AIが活用されている事例です。このほかにも毎週数十億のやりとりを行うAlexa、迅速な処方箋とサポートを提供するAmazon Pharmacy等を通じ、よりよい顧客体験を提供するために生成AIが活用されています。

一般的に生成AIは様々な業界で利用されていますが、特に以下のような事業での活用が目立っています。建築・設備・機器等のメンテナンス事業では、生成AIチャットボットを訓練し、迅速な技術サポートを提供しています。金融事業では、生成AIポートフォリオ管理において、特定の金融目標に合わせた投資戦略を作成するアプリを提供しています。アパレル事業では、生成AIによる仮想フィッティングによりオンラインショッピングの体験を向上させるサービスを提供しています。これら対外的なサービスを提供するソリューションとして、チャットボット、バーチャルアシスタント、会話分析、パーソナライゼーションの技術が利用されています。

本節では代表例として、コンタクトセンターでの通話要約文生成のユースケースを取り上げます。コンタクトセンター業務では、生成AIを活用して、よりよい顧客体験とビジネスの差別化を実現することに大きな期待と関心が集まっています。これまでもコンタクトセンターの責任者は、自動音声応答、Web画面連動、モバイル対応等、時代に合わせて最先端の技術を取り入れながら、より少ないリソースでより多くの成果を上げるよう求められてきました。コンタクトセンター向け生成AIは、チャットボットやセルフサービスのバーチャルアシスタント、エージェントアシスト、パーソナライズされたエクスペリエンスやレコメンデーションなどを改善することにより、人間のような会話機能を駆使して顧客体験を強化します。

## 3.1.1 ユースケース1:コンタクトセンターでの通話要約文生成

コンタクトセンターは、消費者・利用者からの商品注文、電話によるサポート依頼、予約など、顧客と企業をつなぐ存在です。電話対応がうまくいけば、消費者・利用者は企業ブランドに対してポジティブなイメージを持ち、再来店したり、他の人に勧めてくれたりする可能性が高くなります。

よりよい体験を消費者・利用者にしてもらうために、2つの考慮点があります。まず、スーパーバイザーが消費者・利用者の体験の質をリアルタイムで評価できるようにする必要があります。例えば、最初は不機嫌だった消費者・利用者が、エージェント（通話オペレータ）との通話が進むにつれて印象が変わるかどうかをスーパーバイザーが把握できれば、通話終了前に改善アクション

んをとることができます。

次に、エージェントが通話の質を上げるための支援をする必要があります。例えば、リアルタイムの通話書き起こしメモや、3分ごとの通話要約を自動化できれば、エージェントがメモをとる必要がなくなり、通話の文脈に関連した情報やガイダンスを活用できるので、エージェントは消費者・利用者のポジティブな反応を引き出すことに集中できるようになります。

### ● サンプルアーキテクチャ

それでは、上記2点を考慮したアーキテクチャをデザインしてみましょう。図3.1はその構成例です。

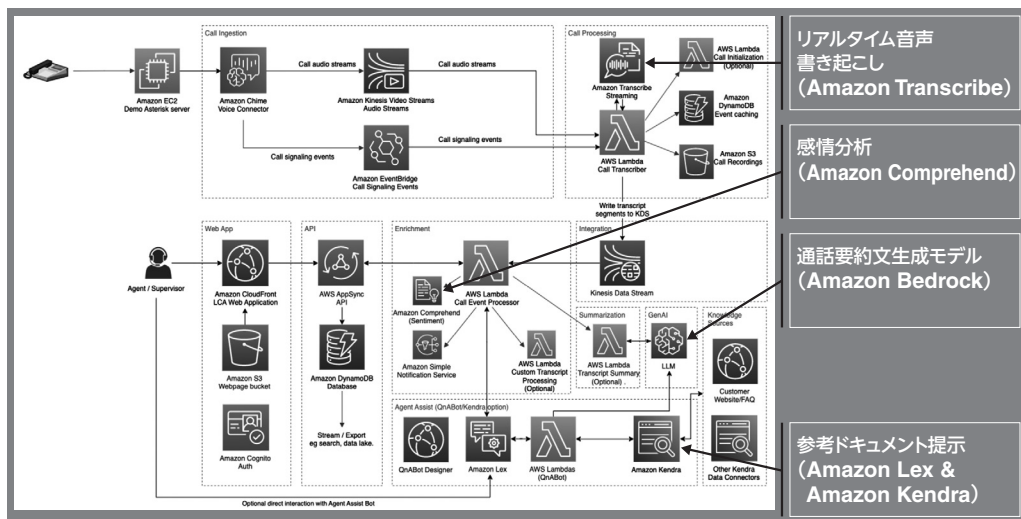


図3.1 サンプルアーキテクチャ(コンタクトセンターでの生成AI活用)

図3.1で使用する主な Building Block を、業務の流れに沿って紹介します。

コンタクトセンターが受電すると、左上の Call Ingestion ブロックから音声がストリームに乗って流れていきます。はじめに右上の Call Processing ブロックで、Amazon Transcribe によりリアルタイムで音声の書き起こしが実行されます。次に真ん中の Enrichment ブロックで、Amazon Comprehend により感情分析が実施されます。

続いて Summarization/Gen AI として、Amazon Bedrock 上で Anthropic 社の基盤モデル Claude を利用して、通話の要約文を生成します。さらに Agent Assist ブロックとして、Amazon Lex と Amazon Kendra を活用して、会話型検索でクエリの曖昧さの解消と質問応答生成を実現し、通話中の推奨事項の品質と文脈の関連性を向上します。

これらの Building Block は、GUI からワンクリックで AWS 環境に生成 AI モデルをデプロイ

することで実現できます。なお、本サンプルアーキテクチャは、2021年12月にAWS Machine Learning Blogに掲載されて以降、生成AIの進化に合わせて日々機能拡張されています。デプロイ方法の詳細については、脚注<sup>2)</sup>のリンクを参照してください。

## ●分析ダッシュボード

本ユースケースでは、スーパーバイザーとエージェントはそれぞれ、**図3.2**のような分析ダッシュボードを受電中に確認することができます。その使い方を説明します。

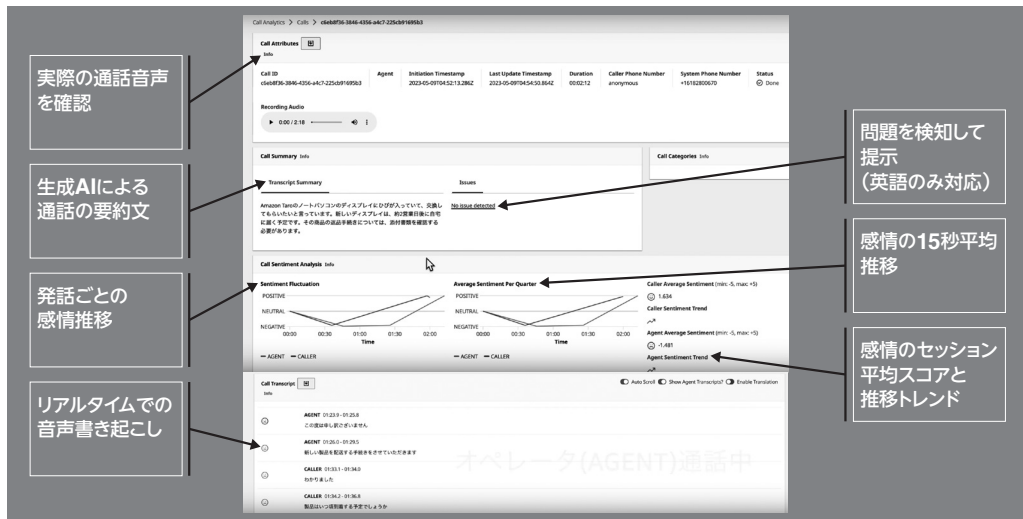


図3.2 分析ダッシュボード(コンタクトセンターでの生成AI活用)

コンタクトセンターが受電すると、エージェントは画面右上のCall IDをクリックします。消費者・利用者の発話内容は、Call Transcript欄にリアルタイムで音声書き起こしが行われ、Call Sentiment Analysisで15秒ごとに感情分析結果と推移が表示されていきます。

今回のサンプルで顧客 (CALLER) である太郎さんのノート PC の交換対応の場合、太郎さんの感情はネガティブから始まっています。このとき、エージェントがスーパーバイザーに分析ダッシュボードを共有すれば、スーパーバイザーはリアルタイム分析を観察できます。エージェン

2) AWS Machine Learning Blog "Live call analytics and agent assist for your contact center with Amazon language AI services"

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

Amazon Web Services ブログ「Amazon 言語系 AI サービスによるコンタクトセンターのライブ通話分析とエージェントアシスト」

<https://aws.amazon.com/jp/blogs/news/live-call-analytics-and-agent-assist-for-your-contact-center-with-amazon-language-ai-services/>

トはアシスト機能を活用して、適切に商品の手配、2営業日以内の発送、故障品の返却方法の案内を行います。その結果、太郎さんの顧客体験が向上し、それを表す発話が確認されると、Call Sentiment Analysisの感情がポジティブに上昇します。

最後に、通話終了後、生成AIによる要約文の作成が開始され、要約文が完成すると、左上の Transcript Summary に表示されます。この分析ダッシュボードのデモ動画は、脚注<sup>3)</sup>のリンクから参照できます。

上記のアーキテクチャと分析ダッシュボードは、あくまで一例です。AWSでは、生成AI機能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、柔軟な試行錯誤を行うことができます。また、生成AIを他のAIサービスと組み合わせることで、自由に機能を拡張できます。

実際の生きた消費者・利用者と向き合う上で、重厚長大な最新の基盤モデルが顧客体験を向上させる最適解とは限りません。業務要件を満たすには、どこまで大規模なモデルが必要なのか検討することが重要です。業務や時代の求めに合わせて、Amazon BedrockやAmazon SageMakerに最新あるいは最適なサイズの基盤モデルをデプロイすることで、企業は自社のAWS環境内でデータの流れを作ることができます。

---

3) 「AWS で簡単に作る生成系 AI モデル(デモ)」コールセンターの通話要約文生成デモ  
<https://aws.amazon.com/jp/blogs/news/aws-aiml-generative-ai-strategy/>

## 3.2 社員の創造性と生産性向上

---

第2章の「責任あるAI」で見たように、生成AIを利用するには、抑止・管理していかなければならないリスクがあります。多くの企業では、リスクを回避しつつ、生成AIの豊かな表現力、圧倒的な処理スピード業務に取り入れるために、限られた社内データで実験を開始しました。便宜上、実験は主に4つのタイプに分類できます。

- ① 会話型検索インターフェースを作ることで、専門的な技術文書や特許情報のドキュメント処理、テキスト要約を行う実験
- ② Amazon Q Developerのようなツールを使って、コード生成やコンテンツ制作を高速化し、従業員の生産性を高める実験
- ③ 組織としてよりよい意思決定を行うために、大量の文書から洞察データを抽出し、組織全体で知識を共有し、プロセスを最適化する実験
- ④ 製品のアイデア出しや、従来型のAIモデル開発に必要なデータ拡張のために生成AIを活用する実験

これらの実験を経て、生成AIの社内利用は様々な業界で進んでいますが、特に以下のような事業での活用が注目されます。

医療事業では、生成AIが医療画像の高精細化と再構築を行うことで、より正確な診断に役立っています。医薬品開発事業では、タンパク質合成に特化した基盤モデルを、企業や組織をまたがる研究機関や医療機関が利用。これにより、新しい分子構造を生成する開発プロセスの加速と、コスト削減を両立しています。製品設計事業では、生成AIを使って、制約条件を考慮しながら新製品のデザインを生成し、設計期間短縮に取り組んでいます。輸送事業では、AIによる故障検知に必要な膨大な学習データを、生成AIによるデータ合成により実現しています。金融事業では、生成AIを使って投資調査レポートや保険書類などを迅速に作成しています。製品販売事業では、生成AIを使って最適な価格戦略を見つけ出したり、製品データに基づく独自の高品質な製品説明を自動生成したりしています。

本節ではこれらを代表して、社内ドキュメントからの回答文生成のユースケースを取り上げます。2023年、生成AIのテクノロジーを実際の業務どのように活用したらよいか、日本企業が最初に取り組んだ実験が、エンタープライズAIアシスタントやエンタープライズ検索を通じた従業員の生産性向上でした。そこで特に注目を浴びたのが、RAG (Retrieval Augmented Generation) を活用したリアルタイム検索でした。

## 3.2.1 ユースケース2:社内ドキュメントからの回答文生成

RAGは「検索拡張生成」と訳されますが、ピンと来ない人は、RAGの頭文字Rのレトリバーバルと、犬のレトリバー種(ラブラトルレトリバーやゴールデンレトリバー等)を重ねて想像してみてください。元々猟犬であり獲物の回収が巧みなレトリバー犬は、ほぼ無傷で獲物を捕らえることのできる軟らかい口を持っており、険しい道の移動や水中の狩猟を行う運動神経に優れ、知性的で聞き分けがよく、機敏な気質を持っている、とされています。次の単語(トークン)を予測するという特性から、生成AIは事実と異なる回答を出力してしまうリスクを持っています。RAGは、生成AIが参照すべきデータを自社データの中から安全に運んでくる、補助犬のような役割を果たします。

企業は、RAGを介して自社データを活用することで、より関連性の高い、コンテキストを意識した情報を社員に提供できます。生成AIは、大量のデータで事前トレーニングされており、どのような質問に対しても自然で流暢な回答が可能です。しかしながら、事前学習の範囲外の、最新情報、専門的なデータ、自社固有のトピックに関する質問には、正確なデータに基づいて答える能力に限界があります。これに対しRAGは、誤った情報で回答するハルシネーションを軽減し、データの出自をもとに利用者の意志決定の根拠を確認できるトレーサビリティも向上させます。

AWSのサービスだけでも、Amazon Bedrock、Sagemaker、Amazon Kendra、Amazon Q for Quicksight/Businessと何種類もの組み合わせでRAGを実装することができますが、ここでは最もシンプルなAmazon Kendraを取り上げてみます。

### ● サンプルアーキテクチャ

図3.3は、ユーザーからの質問に対して、社内ドキュメントを生成するためのBuilding Block

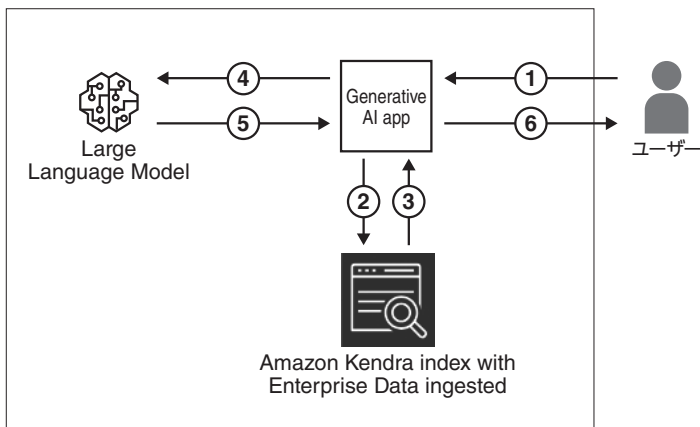


図3.3 サンプルアーキテクチャ(社内ドキュメントの自動生成)

の例です。この働きを業務の流れに沿って紹介します。

①まず、右上のユーザーが社内向け質問文を生成AIアプリケーションに入力します。

②③次に生成AIアプリケーションは、Amazon Kendraを利用して、ユーザー質問に関連するドキュメントを抽出(Retrieve)します。Amazon Kendraが検索する範囲は、自社に特化したインデックス(索引)と、指定したデータへのコネクタにより限定されます。

④⑤生成AIアプリケーションは、抽出されたドキュメントをAmazon BedrockまたはAmazon SageMaker上の基盤モデル(LLM)に入力し、人間の回答に近い自然な言葉で出力された回答を受領します。

⑥最後に、ユーザーは生成AIアプリケーションから、丁寧な回答と、出典元となった参考ドキュメントのリンクを得ます。

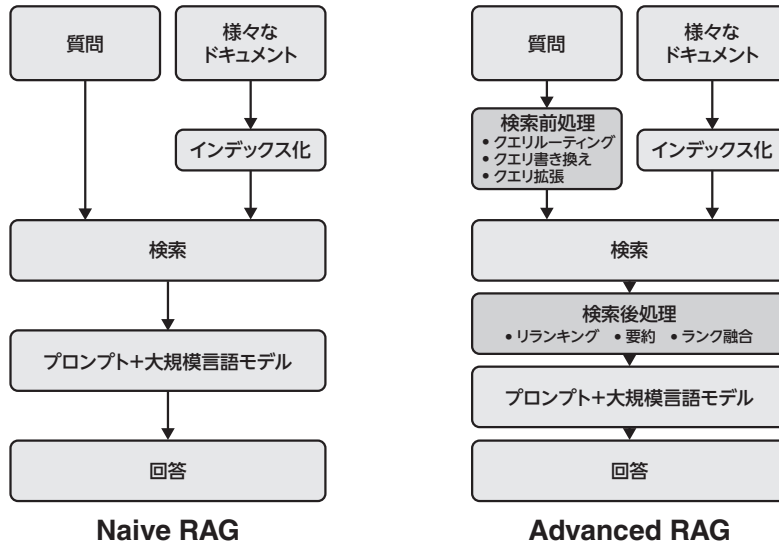


図3.4 Naive RAGとAdvanced RAGの違い

本アーキテクチャはNaive RAGと呼ばれ、2024年5月現在最もシンプルな構成です。ユーザーの質問は多岐に渡り、必ずしも検索対象のデータを意識した質問を出してくれる訳ではありません。そうしたことから、ユーザーの質問を検索に適した形に整形する前処理・後処理を含めたAdvanced RAGという呼称ができました。生成AIの進化に合わせて、RAGの精度は日々向上しています。

このようにAWS環境では、RAGもコンポーネントとして扱えるので、柔軟なアプリケーションの組み換えと試行錯誤が可能です。本サンプルアーキテクチャのデプロイ方法の詳細やAdvanced RAG最新情報については、脚注<sup>4)</sup>のリンクを参照してください。

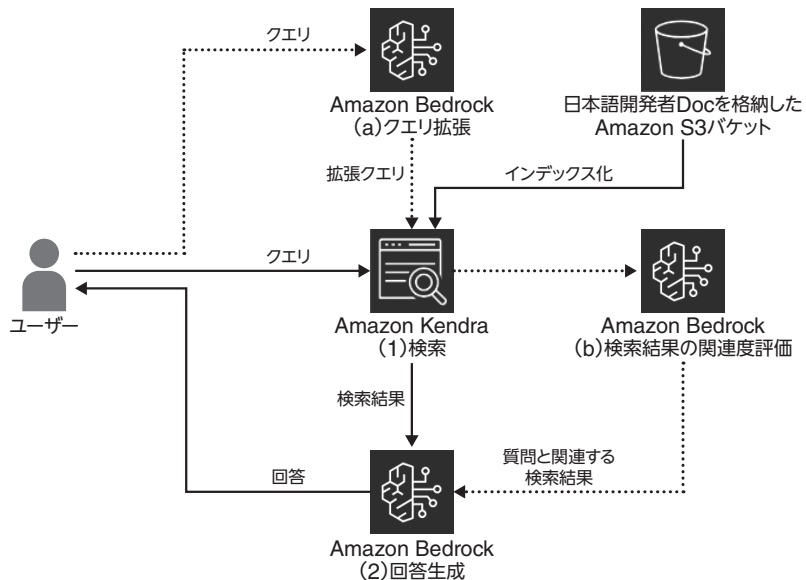


図3.5 AWSでのAdvanced RAGアプリケーションの構成例

- 4) ・ AWS Machine Learning Blog “Quickly build high-accuracy Generative AI applications on enterprise data using Amazon Kendra, LangChain, and large language models”  
<https://aws.amazon.com/jp/blogs/machine-learning/quickly-build-high-accuracy-generative-ai-applications-on-enterprise-data-using-amazon-kendra-langchain-and-large-language-models/>  
 ・ Amazon Web Services ブログ「Amazon Kendra と Amazon Bedrock で構成した RAG システムに対する Advanced RAG 手法の精度寄与検証」  
<https://aws.amazon.com/jp/blogs/news/verifying-the-accuracy-contribution-of-advanced-rag-methods-on-rag-systems-built-with-amazon-kendra-and-amazon-bedrock/>



## 3.3 生成AIアプリケーションに取り組むには？

対外的な顧客体験の向上と、社内の従業員の生産性の向上を支援する2つのユースケースについて見てきました。実際に生成AIの実験を開始すると、多くの企業が現在の自社IT環境では、ユーザーが必要とする関連性の高いデータにそもそも辿り着けていないことが分かってきます。そのためAWSは、まず「アクセスできる社内情報から生成AIの実験を始める」ことを推奨しています。

第2章でも触れたとおり、生成AIアプリケーションの成功に必要なポイントは、「ユースケースの見極め」です。ユースケースが決まれば、集めるべきデータソースが何か定まります。データに辿り着ければ、ユーザーに提供するインターフェースをどこに置か決まります。実験の範囲を5名から10名程度のグループに限定することでユーザーの満足度が向上し、信頼できる自社用語集(コーパス)が構築され、検索に関わるデータ戦略・方針が固まります。あとは必要なユーザーデータの収集を開始するだけです。

次に推奨しているのは「業務に効く生成AIに鍛え、慣れること」です。部門内の利用者の拡大と、アクセス頻度の増加に伴い、ナレッジギャップが明らかになってきます。ユーザーの声を収集し、価値の高いユーザーを見極めることで、データに基づく意志決定が可能になってきます。この段階に来ると、これまで死蔵扱いされていた社内データが検索・利用されるようになり、社内データの価値が向上します。

最後に「生成AIでデータの価値を向上させる」という段階に入ります。部門単位の生成AI活用から、会社横断で適用可能な業務分野の見極めへと進めます。この段階では、あらかじめ成功の指標を設定し、生成AIに必要なデータと、生成AIで価値が見直されるデータの学びの拡大へとつなぎます。ユーザーの要望への対応範囲を拡大し、社内のマニュアル業務や金食い虫タスクの自動化に生成AIを適用していきます。最終的なゴールは「生成AIによる顧客体験の向上」です。競合他社と差別化を図るためのモデルの構成・設定や、モデル自体のファインチューニングを行う分野を見極めていきます。そのために必要なデータを求める取り組みは続きます。

### 3.3.1 差別化要因としてのデータ

自社のニーズに合致したユニークな生成AIアプリケーションを構築したい場合、自社のデータが差別化要因となります。消費者・利用者を深く理解したアプリケーションの違いを生み出すのは、データの違いです。

考えてみると、すべての企業が同じ生成AIの基盤モデルにアクセスできますが、自社のデータの置き場所は企業によって様々です。企業は時代と共に、異なるストレージ、データレイク、

データベース、分析処理基盤、データ統合基盤にデータを置き、それぞれにガバナンスとコンプライアンスを効かせてきました。私たちは生成AIアプリケーションの表面的な部分に惹かれがちですが、企業にとって重要なのは、最適なデータアーキテクチャを使ってデータプロセスとデータ活用を効果的に行うことです。そのためには、以下のような点についての配慮が欠かせません。

まず、生成AIアプリケーションは、基盤モデルを呼び出す以外に、外部システムと連携して顧客体験をサポートするためのデータベースや運用を必要とします。次に、生成AIアプリケーションを自社の業務ドメインに合わせて価値向上を図る場合、データレイクや分析処理基盤に蓄積されたデータやツールとの連動が重要になります。

さらに、生成AIアプリケーションの目的がリアルタイム検索であっても、裏側で取り扱うデータはバッチやストリームで追加・更新されることがあるので、データのアクセス特性や処理方法が異なる可能性があります。異なるデータ特性に対応するパイプラインを設定し、生成AIアプリケーションで違和感なく使えるようにする必要があります。

最後に、ガバナンス、データ品質、プライバシーと法令順守、セキュリティとアクセス制御のプロセスを考慮しなければなりません。

## 3.3.2 生成AIアプリケーションの価値向上のために

生成AIアプリケーションを自社データで最適化する3つの手法、RAG、ファインチューニング、継続的な事前トレーニングを紹介します。これらが自社のビジネスユースケースに最適な精度・コスト・回答速度を満たす最適解のヒントとなれば幸いです。

### ● RAG

はじめに、最も安価で簡単な手法、RAG (Retrieval Augmented Generation) です。先述のとおり、RAGでは既存の生成AIアプリケーションの出力をカスタマイズし、出典元情報を加えることができます。また、基盤モデル自体に手を加える必要がなく、モデルの外部に自社データを置いてやりとりするので、後述のファインチューニングや継続事前トレーニングよりも安価で簡単な手法です。外部データとして、ドキュメントリポジトリ、データベース、APIなど、複数のデータソースを利用できます。RAGは様々なナレッジライブラリから必要に応じてデータを取得し、生成AIアプリケーションの出力を調整・補完するのに役立ちます。

### ● ファインチューニング

ファインチューニングは既存の基盤モデルに対して、自社のビジネスユースケースやタスクに特化した業務ドメイン固有のデータを用いて、モデルの出力フォーマットや応答を自社の要求に

合うように改善する手法です。Amazon Bedrockの場合、ファインチューニング可能な基盤モデルを複製し、少数のラベル付きサンプルデータを提供することで、自社の業務ドメインにカスタマイズされた基盤モデルを作成することができます。

#### ●継続的な事前トレーニング

継続的な事前トレーニングとは、企業が持つラベルなしの非構造データセットを利用して、複製された基盤モデルをカスタマイズする技術です。大規模言語モデルの場合、ファインチューニングとは異なり、ラベルなしの大量の自社テキストデータを読み込ませて、自社データに関する新たな知識を獲得させます。

## 3.3.3 成果をあげるビジネスユースケース

2024年・2025年は多くの企業にとって、「生成AI実装元年」です。本章の最後に、使用方法やアーキテクチャ以外の話題として、成果をあげるビジネスユースケースに共通する重要なトピックを紹介します。

#### ●ROI

第1にROIです。初期の実験、対象を絞った実装、広範囲な導入へとスケールアップしていく際に、ビジネス価値とROIを評価する必要があります。2023年に熱狂的なブームにおされて生成AIアプリケーションを導入した企業も、2024年現在では、生成AIを活用する様々なツールやソリューションの選択肢が増えたため、改めて自社のビジネスユースケースにとって適切で測定可能なKPIとメトリクスを設定・追跡し、スケールアップの前に確認するワークショップを開いています。

#### ●最適化

第2に最適化です。AWSは生成AIがブームになる以前から、「どの基盤モデルもそれぞれで全ての業務に適用するわけではない」と訴え続けました。最新・最速といった特性ばかりに拘らず、自社のビジネスユースケースに必要な精度・コスト・回答速度をもつ基盤モデル、および外部システムと連携するツールを選択して最適化すべきです。生成AIアプリケーションの実験から実装に移行する企業は、テクノロジーの進歩をどのタイミングで自社に取り入れるか、モニタリングと改善計画を立てて、長期的に利用されるアプリケーションを構想しデザインしていく必要があります。

#### ●コンプライアンスとガバナンス

第3に、社内のコンプライアンスとガバナンスの体制を整える必要があります。開発時に得られる人材と資金が運用時にも継続されるとは限りません。一方で限られたリソースの中で、リスク管理、信頼の維持、そして責任あるAIとして構築をし続けることは、企業のAI利用にとって不可避です。生成AIアプリケーションを実験から実装、より広範囲な業務へとスケールアップするとき、外部の消費者・利用者も社内の従業員もこのことに無関係ではいられなくなります。生成AIアプリケーションについて責任ある使用がなされるよう、次の段階へ進む前に、コンプライアンスおよびガバナンスの担当者とルールを共有しておかねばなりません。

#### ●インフラ

最後に、スケールアップあるいはスケールダウンに耐えうる適切なインフラストラクチャを持つことです。生成AIは豊かな表現力と驚異的なスピードで浸透した画期的技術ですが、広範な企業活動のほんの一部で利用されるに過ぎません。実験が成功したら、どのようにそれをスケールアップし、コンプライアンスとガバナンスを効かせ、安全に構築が続けられるかについて、関連する部門、経営層、消費者・利用者の理解を常に得ながら、この革新的なテクノロジーに取り組む必要があります。

企業にとって有益でも社会にとって好ましくない場合、適用範囲を見直し、最適なユーザーと業務範囲に絞り込んで再活用すべきケースもあります。目まぐるしく変わるビジネス環境に適合可能な、柔軟かつ安全なインフラストラクチャでなければ、生成AIアプリケーションの本番利用を支えることはできません。

# 第4章

## Amazon Bedrockで 生成AIに触れる

本章では実際にAWSを利用して、テキストの生成と画像の生成を行います。本章の中にはコードの紹介もありますが、プログラミングをやったことがなくても大丈夫なように構成していますので、どうか怖がらずに試してください。

筆者はソリューションアーキテクトとして様々なお客様と接する機会が多いのですが、非エンジニアの方（プロダクトマネージャーや業務の意思決定者など、エンジニアにアプリケーションの要求を出す人）がコードに触ったことがあるほうが、アプリ開発の質が高く、また開発のスピードが速いように感じます。コードを書いて実行した経験があると、エンジニアから見て無理な要求が減りますし、自身の要求の解像度が上がります。例えば生成AIは一般的に処理が重く、2024年現在で軽量なモデルであっても、1つのリクエストを処理するのに数秒かかってしまいます。アプリケーションの要求定義において、一度も生成AIを扱ったことのない人から、生成AIの出力がミリ秒単位でないと実現できないような要求が出されて、会話が噛み合わずになかなか話がまとまらない場面をしばしば目撃します。一度の経験で見える世界がガラッと変わるので、ぜひ試してください。



図4.1 画像生成の例

# 4.1 改めてAmazon Bedrockとは？

先述のとおり、AWS では生成 AI のために3階層でサービスを提供しています。

一番上はアプリケーションレイヤーです。アプリケーションレイヤーは現在 Amazon Q というサービス名に統一されています。そのひとつ、Amazon Q Businessでは、ビジネスユーザー向けにあらかじめ登録されたドキュメントをベースにして、自由にチャットで質問できます。例えば、福利厚生資料を登録しておけば、初年度の年次有給休暇の日数を答えてくれるといった具合です。また、Amazon Q in Amazon QuickSightでは、Amazon QuickSightというBIツールにインテグレーションして、データを自然言語で可視化できます。Amazon Q Developerには開発者向けの機能が多数用意されています。VSCodeやJetBrains等のアプリケーション統合開発環境にAIコード補完機能をアドオンしたり、AWS マネジメントコンソールからチャット形式でAWSの使い方を問い合わせたりでき、開発工程を幅広く支援します。

これらはOut of the Box<sup>1)</sup>で使うことを前提としているため、業務にフィットするのであればすぐに使い始められる便利なものですが、個々の皆様が求める生成AIを用いたアプリケーションとは違うものかもしれません。

そこで用意されているのが、2番目のレイヤーであるAmazon Bedrockというサービスです。Amazon BedrockはAPI経由で生成AIのモデルを呼び出す機能や、モデルを便利かつ安全に使うためのツール群を提供しています。

ところで、生成AIのモデルはText to Text（テキストからテキストを生成）やText to Image（テキストから画像を生成）などの用途に応じて使い分ける必要があり、1つのモデルで全てのアプリケーションの要件を満たすことは不可能です。また同じ機能、例えばText to Textのモデルでも、会話や創作が得意なモデルもあれば、RAG（Retrieval Augmented Generation：検索拡張生成）が得意なモデル、コード生成が得意なモデル、単一の言語が得意なモデル、など多様で、要求に合わせてモデルを選択する必要があります。

Amazon Bedrockには、Amazonが独自に開発したモデルのほか、AnthropicやMistral AI、Metaといったサードパーティーのモデルプロバイダーが開発した生成AIモデルも使用できるようになっており、まさにAmazonの精神に相応しい豊富な品揃えになっています。これから開発しようとしているアプリケーションに合うモデルを選ぶことができます。

しかし、Amazonやサードパーティーのモデルではなく、自前のモデルを必要とするケースもあるでしょう。そのような場合のために用意されているのが一番下のレイヤーであり、ユーザー独自の生成AIモデルを開発・学習・推論するために必要な機能の全てが用意されています。モデ

1) カスタマイズすることなくそのままサービスを使用すること。IT業界の慣用語であり「導入後、直ちに使用できる」という意味です。

ルの訓練やホストするための機能だけでなく、コンピューティングリソースのGPUはもちろん、訓練専用のチップや推論専用チップもあり、コストの最適化を図ることができます。本章ではこのあと、2番目のレイヤー Amazon Bedrockの基本的な使い方を紹介します。

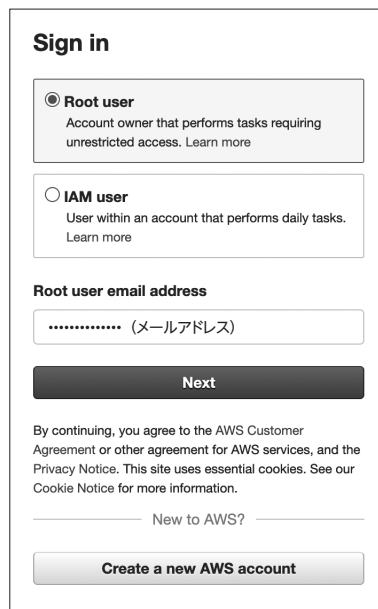
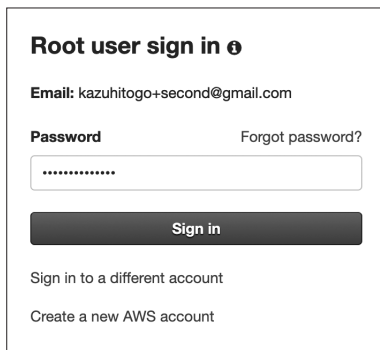


## 4.2 Amazon Bedrockの利用準備

便利な Amazon Bedrock ですが、まずは AWS アカウントを作らないことには何も始まりません。また、AWS ではセキュリティが最優先事項であり、ユーザーが Amazon Bedrock を使用するために適切な権限 (ポリシー) を割り当てるのが好ましいです。本節ではアカウントを作成して、ポリシーを割り当てるところまでをガイドします。


### 4.2.1 アカウント作成

AWS でアカウントを作成する方法について、日本語の丁寧なガイドは「AWS アカウント作成の流れ (<https://aws.amazon.com/jp/register-flow/>)」にまとまっています。そのページを確認しながら、「Sign up for AWS (<https://portal.aws.amazon.com/billing/signup>)」から、アカウントの作成を行ってください。なお、アカウント作成にあたっては、①メールアドレス、②クレジットカードまたはデビットカード (この章を一通り実行すると 10 円程度の費用がかかります)、③SMS もしくは音声通話が可能で電話番号が必要です。



アカウント作成が完了すると、サインアップ完了の画面が出ますので、「AWS マネジメントコンソールにお進みください」を押下してください。その後、アカウント作成時のメールアドレスとパスワードでログインして、AWS マネジメントコンソールのホームの画面に移動します。

最後に、使用するリージョン<sup>2)</sup>を選択します。Amazon Bedrock は様々な地域で使えますが、今回は、最新のモデルが最初に反映されることが多いバージニア北部を選択することにします。マネジメントコンソールの右上から「バージニア北部」を選択しましょう。



## 4.2.2 IAMユーザーの作成と設定

以上で、AWS マネジメントコンソールにログインできました。ただし、現在ログインしているユーザーは、「ルートユーザー」と呼ばれるものです。これは自身のAWS アカウント内において、全てのAWS サービスとリソースに対して完全なアクセス権限を持っています。このままルートユーザーを使うのはセキュリティ上好ましくありません。ですので、本章でAmazon Bedrockを扱うのに必要な権限(ポリシー)を持ったユーザーを作成します。

本来はIAMユーザーの作成においても、ルートユーザーではなく、管理者用のIAMユーザーを作成した後、その管理者権限の下でAmazon Bedrockのアクセスを許可すべきです。しかし、ここでは簡略化のため割愛して、ルートユーザーでIAMユーザーを作成することにします。

アカウント作成後に本来やるべきことは、「アカウント作成後すぐやるセキュリティ対策」のページ (<https://pages.awscloud.com/JAPAN-event-OE-Hands-on-for-Beginners-Security-1-2022-reg-event.html>)にまとまっているので、AWSに触ったことがない方はぜひ参照してください。

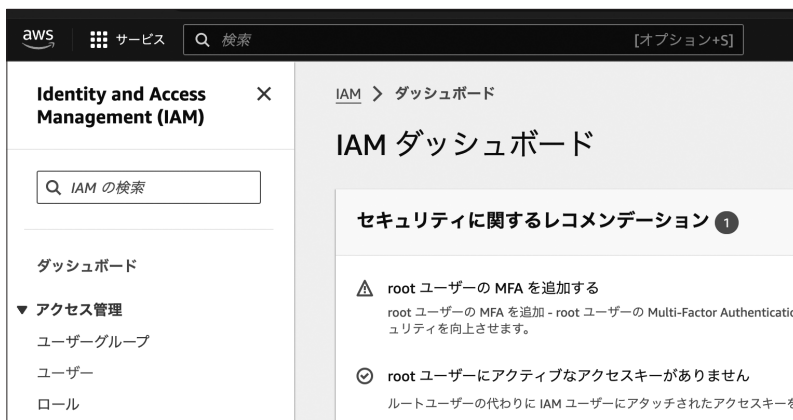
最初に、マネジメントコンソール画面上部の検索窓に「IAM」と入力します。すると、「IAM」というサービスが表示されるのでクリックします。

2) AWSのサービス提供地域を指します。ただし、日本から海外のリージョンを指定して使うこともできます。あくまでサービスを提供している物理的な地域を指します。



## ●ユーザーを作成する

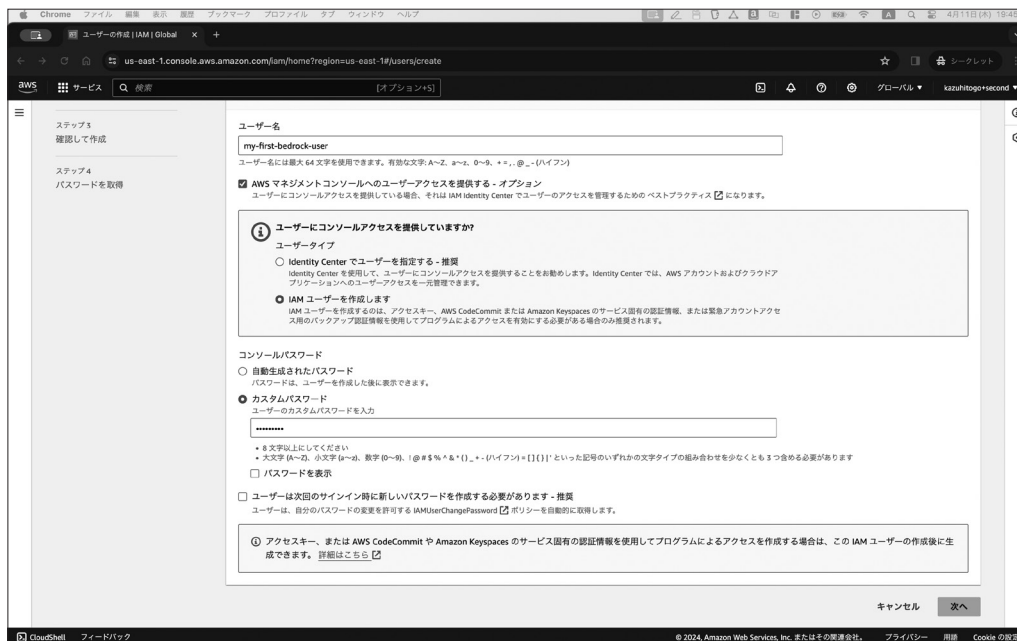
続いて、左側のペインから「ユーザー」というリンクをクリックします。



ユーザー一覧画面が表示されます(アカウントを作った直後はユーザーがないので、「表示するリソースがありません」と表示されます)。画面右上の「ユーザーの作成」をクリックします。



作成するユーザーの詳細設定画面に遷移するので、任意のユーザー名を入力し、「AWS マネジメントコンソールへのユーザーアクセスを提供する」にチェックを入れ、「IAM ユーザーを作成します」にチェックし、パスワードを設定して「次へ」をクリックします。



## ●ポリシーを設定する

次に、ユーザーに付与する権限(ポリシー)を選択します。必要なポリシーは「AmazonBedrockFullAccess」と「AWSMarketplaceManageSubscriptions」の2つです。

AmazonBedrockFullAccessでは、文字どおりAmazon Bedrockの操作が何でもできるようになります。もう少し権限を絞ることもできます(例えば今回はモデル呼び出しができればOKで、モデルのカスタマイズ機能などは不要といった場合など)が、ここでは簡単のためにこのポリシーを使用します。

また、今回はサードパーティーのモデル(Claude)を使いますので、サードパーティーのモデルを使えるようにするために、AWSMarketplaceManageSubscriptionsというポリシーを付与します。一度使えるようにしたらこの権限は不要なので、外してしまっても構いません。

それぞれのポリシーにチェックを入れ、「次へ」をクリックします。

## 許可を設定

既存のグループにユーザーを追加するか、新しいグループを作成します。グループを使用することは、職務機能別にユーザーの許可を管理するためのベストプラクティスの方法です。詳細はこちら [🔗](#)

### 許可のオプション

ユーザーをグループに追加

ユーザーを既存のグループに追加するか、新しいグループを作成します。グループを使用して、職務別にユーザーの許可を管理することをお勧めします。

許可のコピー

既存のユーザーから、すべてのグループメンバーシップ、アタッチされた管理ポリシー、およびインラインポリシーをコピーします。

ポリシーを直接アタッチする

ユーザーにマネージドポリシーを直接アタッチします。ベストプラクティスとして、代わりにグループにポリシーをアタッチすることをお勧めします。次に、ユーザーを適切なグループに追加します。

### 許可ポリシー (1/1186)

新しいロールにアタッチする 1 つまたは複数のポリシーを選択します。

絞り込みタイプ
すべてのタイプ
3 - 数

ポリシー名	タイプ	アタッチされたエンティティ
<input checked="" type="checkbox"/> AmazonBedrockFullAccess	AWS 管理	0
<input type="checkbox"/> AmazonBedrockReadOnly	AWS 管理	0
<input type="checkbox"/> AmazonSageMakerCanvasBedrockAccess	AWS 管理	0

▶ 許可の境界を設定 - オプション

キャンセル 前へ 次へ

© 2024, Amazon Web Services, Inc. またはその関連会社。 [プライバシー](#) [用語](#) [Cookie の設定](#)

## 許可を設定

既存のグループにユーザーを追加するか、新しいグループを作成します。グループを使用することは、職務機能別にユーザーの許可を管理するためのベストプラクティスの方法です。詳細はこちら [🔗](#)

### 許可のオプション

ユーザーをグループに追加

ユーザーを既存のグループに追加するか、新しいグループを作成します。グループを使用して、職務別にユーザーの許可を管理することをお勧めします。

許可のコピー

既存のユーザーから、すべてのグループメンバーシップ、アタッチされた管理ポリシー、およびインラインポリシーをコピーします。

ポリシーを直接アタッチする

ユーザーにマネージドポリシーを直接アタッチします。ベストプラクティスとして、代わりにグループにポリシーをアタッチすることをお勧めします。次に、ユーザーを適切なグループに追加します。

### 許可ポリシー (2/1186)

新しいロールにアタッチする 1 つまたは複数のポリシーを選択します。

絞り込みタイプ
すべてのタイプ
1 - 数

ポリシー名	タイプ	アタッチされたエンティティ
<input checked="" type="checkbox"/> AWSMarketplaceManageSubscriptions	AWS 管理	1

▶ 許可の境界を設定 - オプション

キャンセル 前へ 次へ

© 2024, Amazon Web Services, Inc. またはその関連会社。 [プライバシー](#) [用語](#) [Cookie の設定](#)

確認画面に遷移するので、間違いがなければ「ユーザーの作成」をクリックします。

### 確認して作成

選択内容を確認します。ユーザーを作成した後、自動生成されたパスワード (有効になっている場合) を表示およびダウンロードできます。

#### ユーザーの詳細

ユーザー名 my-second-bedrock-user	コンソールパスワードのタイプ Autogenerated	パスワードのリセットが必要 はい
---------------------------------	---------------------------------	---------------------

#### 許可の概要

< 1 >

名前	▲ タイプ ▼	次として使用:
AmazonBedrockFullAccess	AWS 管理	許可ポリシー
AWSMarketplaceManageSubscriptions	AWS 管理	許可ポリシー
IAMUserChangePassword	AWS 管理	許可ポリシー

#### タグ - オプション

タグは AWS リソースに追加できるキーと値のペアで、リソースの特定、整理、検索に役立ちます。このユーザーに関連付けるタグを選択します。

リソースに関連付けられたタグはありません。

新しいタグを追加する  
最大 50 個のタグを追加できます。

キャンセル 前へ ユーザーの作成

すると、新しく作成したユーザーのログイン URL とユーザー名、パスワードが表示されますので、この URL にアクセスしてログインします。

### パスワードを取得

以下のユーザーのパスワードを表示およびダウンロードするか、AWS マネジメントコンソールにサインインするための手順を E メールでユーザーに送信できます。これは、このパスワードを表示およびダウンロードできる唯一の機会です。

#### コンソールサインインの詳細

E メールでのサインイン手順

コピー済み

サインイン URL

https:// [URL]

ユーザー名

my-first-bedrock-user

コンソールパスワード

\*\*\*\*\* 表示

キャンセル .csv ファイルをダウンロード ユーザーリストに戻る

**aws**

### Sign in as IAM user

**Account ID (12 digits) or account alias**

..... (アカウント番号)

**IAM user name**

my-first-bedrock-user

**Password**

.....

Remember this account

**Sign in**

Sign in using root user email

Forgot password?

再度、マネジメントコンソールの画面が出ればユーザー作成の完了です。次節はこの画面から続きます。Amazon Bedrockに関する権限のみを付与しているの、ご覧の通り、管理系の機能へのアクセスは拒否されていることがわかります。

コンソールのホーム

デフォルトレイアウトにリセット + ウィジェットを追加

最近アクセスしたサービス

- CloudWatch
- Amazon Kendra
- CloudFormation
- S3
- Amazon SageMaker
- Amazon Polly
- Amazon Bedrock
- Billing and Cost Management
- API Gateway
- Lambda
- Cognito
- IAM

すべてのサービスを表示

アプリケーション (0) 情報

アプリケーションを作成

リージョン: US East (N. Virginia)

us-east-1 (現在のリージョン) アプリケーションの検索

名前	説明	リー...	送信元アカウント
アクセス拒否			

myApplications に移動

AWS へようこそ

AWS の開始方法  
AWS を最大限に活用するために基礎を学び、有益な情報を見つけましょう。

トレーニングと認定  
AWS のエキスパートから学び、スキルと知識を深めましょ

AWS Health 情報

ヘルスデータなし

コストと使用状況

今月のコスト  
アクセス拒否

費用の内訳  
アクセス拒否

予測される月末のコスト  
アクセス拒否


節約の機会  
アクセス拒否

## 4.3 AWSのコンソールから使う

AWSでは、ほとんどのサービスをマネジメントコンソールから簡単に利用できます。本節では、Amazon Bedrockについても同様にマネジメントコンソールから操作して、どのように使えるのかを試してみましょう。

### 4.3.1 モデルアクセスの有効化

最初に、使用するモデルを有効化する必要があります。この有効化もマネジメントコンソールからできます。マネジメントコンソールの検索窓に「Bedrock」と打ち込み、Amazon Bedrockのサービスをクリックします。



左上のハンバーガーメニューをクリックし、ベースモデルをクリックします。





ベースモデル一覧が表示されるので、「モデルアクセスをリクエスト」をクリックします。

Amazon Bedrock > ベースモデル

**ベースモデル** 検索

Amazon Bedrock を利用すると、Amazon や先駆的な AI スタートアップから提供される高品質モデルを使用して、生成系 AI アプリケーションを開発およびスケールできます。

Q リソースを検索

▼ **Claude | by Anthropic (5)**

Claude 3 は、Anthropic の最先端のビジョンおよびテキスト AI モデルファミリーです。このファミリーの 3 つのモデルである Haiku, Sonnet, Opus では、インテリジェンス、スピード、コストについて、ビジネスニーズに合ったぴったりの組み合わせを選択できます。

プロバイダの詳細を表示

<p><b>Claude v2.1</b></p> <p>Anthropic   Text モデル   最大 200k トークン</p> <p>説明</p> <p>Claude 2 のアップデートでは、コンテキストウィンドウが2倍になり、さらに信頼性、幻覚率、長いドキュメントやRAG コンテキストでの証拠に基づく精度が向上しました。</p>	<p><b>Claude v2</b></p> <p>Anthropic   Text モデル   最大 100k トークン</p> <p>説明</p> <p>洗練された対話やクリエイティブなコンテンツ生成から、詳細な指示実行まで、幅広いタスクに対応する Anthropic の多機能モデル。</p>
---	--

画面右上の「モデルアクセスを管理」をクリックします。

Amazon Bedrock > モデルアクセス

**モデルアクセス** 検索

Bedrock を利用するには、Bedrock の FM に対するアクセスをリクエストする必要があります。そのためには、正しい IAM 許可 が必要で、一部のモデルでは、アクセスをリクエストする前に、まずユースケースの詳細を送信する必要があります。これらのモデルの詳細については、プロバイダページを参照してください。

ベースモデル (24)

モデル | アクセスのステータス | モダリティ | EULA

AI21 Labs			
└ Jurassic-2 Ultra	リクエスト可能	テキスト	EULA
└ Jurassic-2 Mid	リクエスト可能	テキスト	EULA
Amazon			
└ Titan Embeddings G1 - Text	リクエスト可能	埋め込み	EULA
└ Titan Text G1 - Lite	リクエスト可能	テキスト	EULA
└ Titan Text G1 - Express	リクエスト可能	テキスト	EULA
└ Titan Image Generator G1	リクエスト可能	イメージ	EULA
└ Titan Multimodal Embeddings G1	リクエスト可能	埋め込み	EULA
Anthropic	ユースケースの詳細を送信		
└ Claude 3 Sonnet	ユースケースの詳細は必須です	テキストとビジョン	EULA
└ Claude 3 Haiku	ユースケースの詳細は必須です	テキストとビジョン	EULA

今回使用するモデルの1つである Anthropic 社の Claude はユースケースの入力が必須なので、「ユースケースの詳細を送信」をクリックします。

Amazon Bedrock > モデルアクセス

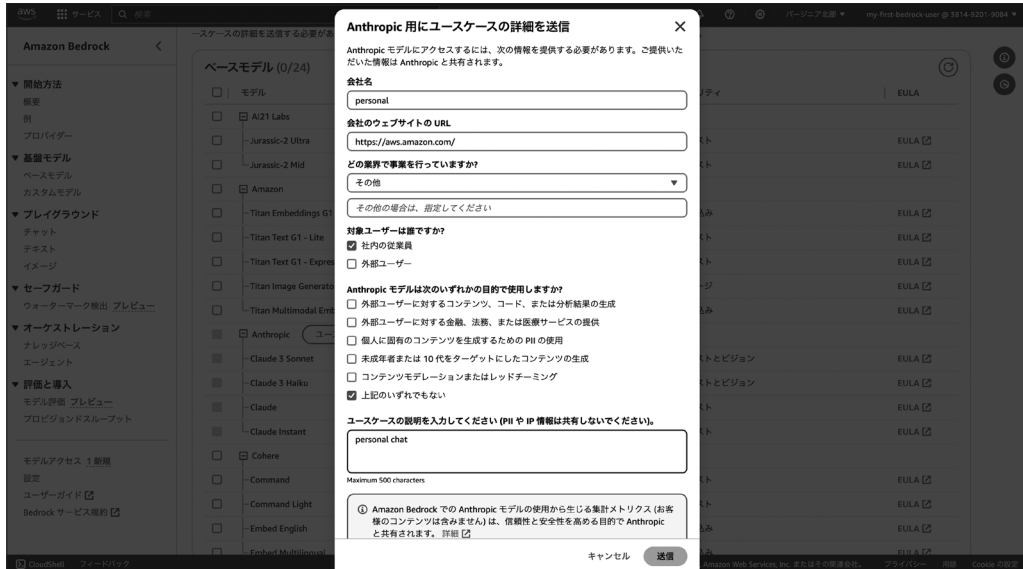
ユースケースの詳細を送信する必要があります。これらのモデルの詳細については、プロバイダページを参照してください。

ベースモデル (0/24)

モデル | アクセスのステータス | モダリティ | EULA

AI21 Labs			
└ Jurassic-2 Ultra	リクエスト可能	テキスト	EULA
└ Jurassic-2 Mid	リクエスト可能	テキスト	EULA
Amazon			
└ Titan Embeddings G1 - Text	リクエスト可能	埋め込み	EULA
└ Titan Text G1 - Lite	リクエスト可能	テキスト	EULA
└ Titan Text G1 - Express	リクエスト可能	テキスト	EULA
└ Titan Image Generator G1	リクエスト可能	イメージ	EULA
└ Titan Multimodal Embeddings G1	リクエスト可能	埋め込み	EULA
Anthropic	ユースケースの詳細を送信		
└ Claude 3 Sonnet	ユースケースの詳細は必須です	テキストとビジョン	EULA
└ Claude 3 Haiku	ユースケースの詳細は必須です	テキストとビジョン	EULA

それぞれの欄へ適切に入力し、「送信」をクリックします。



すると、Anthropic 社の Claude にもチェックを入れることができますようになります。今回は「Titan Image Generator G1」と「Claude 3 Haiku」というモデルを使用するので、それぞれにチェックを入れます。



画面の最下部までスクロールし、「モデルアクセスをリクエスト」をクリックします。



それぞれのモデルに「アクセスが付与されました」と表示されれば準備完了です。アクセスが付与されるまでに数分間かかることがありますので、ブラウザをリロードしながら待ちましょう。

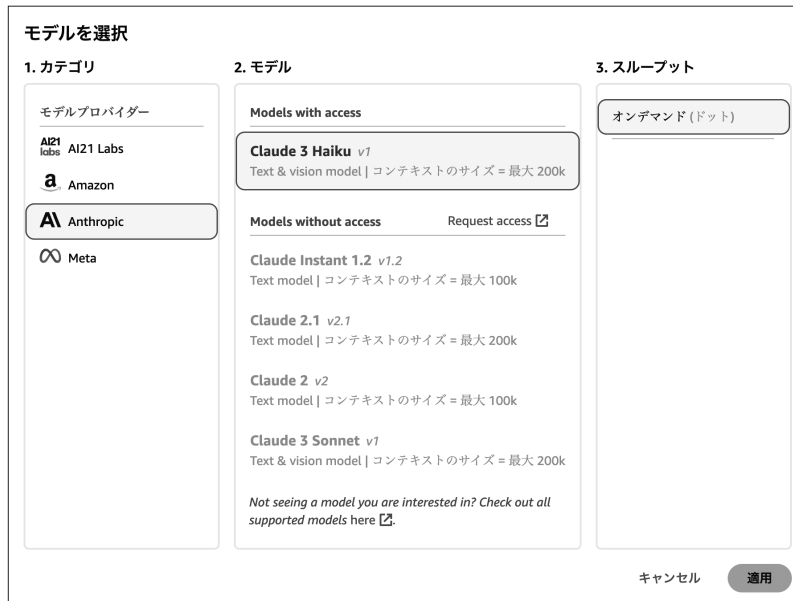


## 4.3.2 Claude 3でチャット

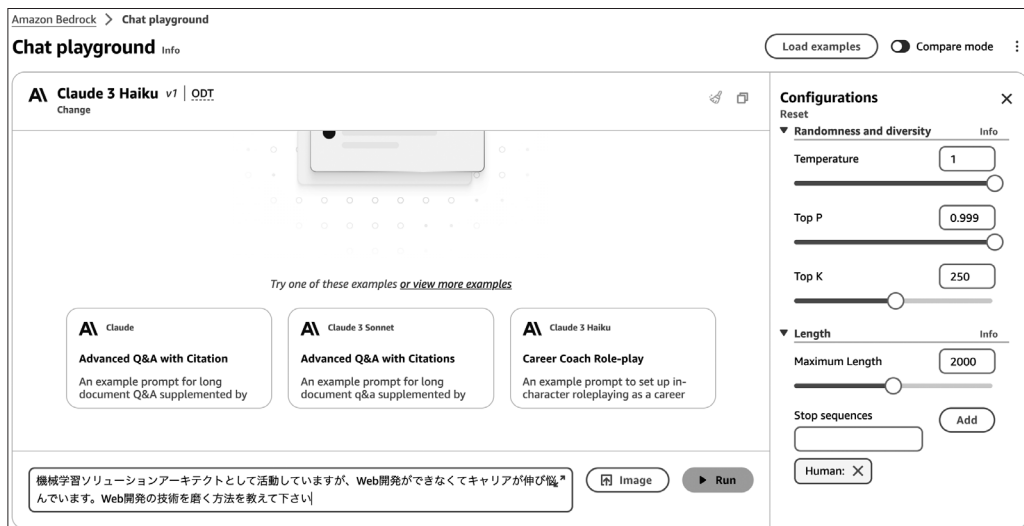
準備が整ったので、いよいよマネジメントコンソールから生成AIを呼び出してみましょう。最初はチャットができる Claude 3 Haiku というモデルを試します。左側のペインから「チャット」をクリックすると、チャットのプレイグラウンドが表示されるので、「モデルを選択」をクリックします。



モデル選択画面で「Anthropic」を選択し、「Claude 3 Haiku」を選択して「適用」をクリックします。



まずはClaude 3 Haikuに人生相談をしてみましょう。筆者の最近の悩みである、「機械学習ソリューションアーキテクトとして活動していますが、Web開発ができなくてキャリアが伸び悩んでいます。Web開発の技術を磨く方法を教えてください」と入力して「Run」をクリックしてみます。みなさんは自由にAIに質問か雑談を試してみてください。



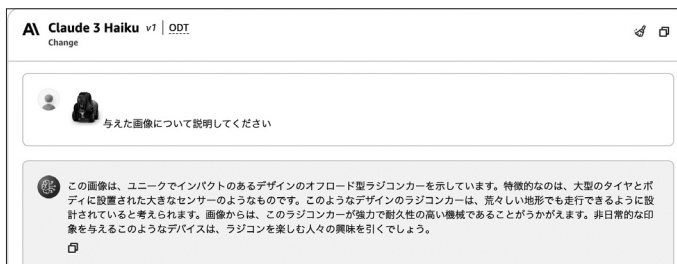
すると、なかなかの回答をしてもらえました。



自分にとって、よりの確な回答がほしい場合は、前提条件をいろいろ加えるとよいでしょう。上の例では、「なぜWeb開発が必要なのか」を入れると、より具体的に回答してくれます。筆者の場合は、「機械学習のモデルを動かすことしか考えてこなかったが、エンドユーザーが機械学習のモデルを動かすにはGUIが必要であり、その開発がしたいから」です。すると、機械学習のモデルを動かすためのGUIにフォーカスした話をしてくれるはずです。あるいは自分のWeb開発の現在のスキルや要望を入れてもいいでしょう。「過去にLAMP環境とjQueryをかじったことがある」とか、「フロントはReactを学びたい」などです。詳細な質問をすればそこにフォーカスした回答を返してくれます。

また、AIの回答に対して、重ねて質問することもできますので、AIの回答の詳細を聞きたい場合や、もらった回答が少し期待とズレているなど思ったときは、追加で質問や要望を出すといいでしょう。

Claude 3シリーズ (Haiku, Sonnet, Opus) には、画像を読み込ませて質問することもできます。AWS DeepRacerの写真を与えて質問してみましょう。



「Image」をクリックしてDeepRacerの画像をアップロードし、「与えた画像について説明してください」と質問してみました。

すると、「ラジコンカー」と回答してくれました。DeepRacerは電波で操作しないので、正確にはラジコンではない(人間によるコントロールではなく、AIが考えて自走します)のですが、知らない人が見たらラジコンに見えるので、写真を読み解く能力が高いことは確かです。

Claude 3シリーズには様々な用途があり、文字の読み取りやシーンの説明、メタデータの生成などいろいろなところで使われています。ぜひ、ご自身のワークロードにも適用してみてください。

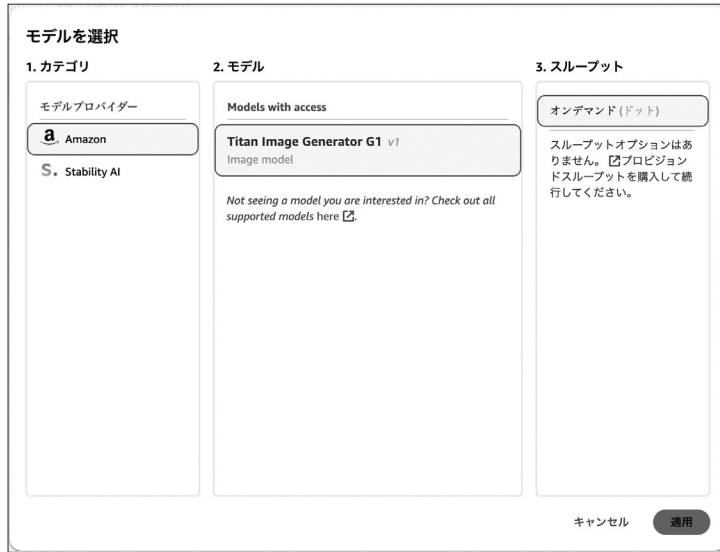
## 4.3.3 Titan Image Generatorで画像生成

生成AIと聞くと、チャットを連想する方が多いと思いますが、画像生成でも生成AIがよく利用されています。本項では、Amazonが開発した画像生成モデルのTitan Image Generatorを使って画像を生成してみましょう。

画面左側のペインから「イメージ」をクリックしてイメージのプレイグラウンドを表示させ、「モデルを選択」をクリックします。



続いて、カテゴリで「Amazon」を選び、モデルで「Titan Image Generator G1」を選んで、「適用」をクリックします。



さっそく画像を生成してみましょう。

下のテキストボックスには、AIに対する命令（プロンプト）を入力します。「glass bottle, grapes juice, white table, blue sky, sun」と入力し、さらに負のプロンプト（Negative Prompt）に「ugly, blurry, distorted, low quality, text, logo, watermark」と入力します。Negative Promptとは「こういう画像は生成するな」という命令です。最後に「実行」をクリックすると画像が生成されます。（カラーでお見せできないのが残念ですが）飲みたくなるようなぶどうジュースを生成できました。



プロンプトにphotographicなどと加えると実写風になったり、animeと加えるとアニメ風になったりするので、いろいろ試してください。

ここでは割愛しますが、画像をテキストで修正 (Inpainting) することもできます。例えばこの生成されたぶどうジュースをオレンジジュースにしたり、背景の空を曇天にしたり、写真の部分を指定して他の画像に変えるなどです。ほかにも、画像の枠外を描画して拡張する機能 (Outpainting) や、画像のコンテンツを維持しつつスタイルや背景を変更する機能 (Variation) があるので、ぜひ試してみてください。



# 4.4 APIからAmazon Bedrockを使う

生成AIをアプリケーションに組み込むとなると、これまでのようにマネジメントコンソールからAmazon Bedrockを使うわけにはいきません。アプリケーションの中から生成AIを呼び出す必要があります。

Amazon BedrockはそのためのAPI (Application Programming Interface) を公開しており、アプリケーションから簡単に呼び出せます。本節ではプログラミング言語のPythonを用い、Amazon BedrockのAPIを利用して生成AIを呼び出す例を紹介します。

## 4.4.1 実行環境とプログラミング言語

言うまでもなく、プログラミングには実行環境が必要です。APIで公開しているので、Amazon Bedrockに接続できる環境であれば、手元のPCでもAmazon EC2でもAWS Lambdaでもどこでも使えるのですが、ここではAWS CloudShellという環境を使うことにします。

AWS CloudShellは、先ほど4.2節で作成したIAMユーザーがあれば、必ず利用できます。また、AWS CloudShellでは、ログイン中のIAMユーザーの権限でターミナルを使用して、コマンドを打ち込むことができます。

使用言語について、APIはWeb APIなので、https でリクエストができればどんな言語でも使えますが、AWSのSDKが用意されている言語 (Java、Ruby、Node.js、PHP、.NET、etc...) を用いると認証を意識しなくて済むのでお勧めです。本節ではAIでよく用いられるPythonの例を紹介します。他の言語でも似たような形で使用できますので、普段使っている言語でも試してみてください。

CloudShellはマネジメントコンソールのどこからでも呼び出せます。画面上部にある四角形の中に「>\_」と書かれたアイコンをクリックすると、画面下部にCloudShellの画面が現れます。

さっそく使ってみましょう。

CloudShellの画面に「Python」と打ち込んでEnterキーを押下してください。以下のような画面が表示されれば、Pythonを対話的に使用する準備は完了です。




試しにPythonで四則演算をしてみましょう。以下のコードを入力します。「#」以降の文字列はコメントであり、コードの解説のために記載していますが、入力する必要はありません（入力してもコード実行時は無視されます）。

```
print(0.1+0.1+0.1) # 0.3
print(2-3) # -1
print(-3*-2) # 6
print(1/5) # 0.2
```

無事、Pythonで四則演算の結果を出力できたはずですが、`print()`のカッコの中に数式を入れると、計算して結果を画面に出力してくれます。とても簡単ですね。

ちなみに、これらの演算はAIでもなんでもなく、ただの四則演算ですが（といってもAIの中で行っているのは大量の四則演算ですが）、最初の足し算の結果が少しへんです。コンピュータは内部的に数を2進数で扱うのですが、2進数では0.1を正確に表現できないので、その誤差がたまって0.300...4という数字を出力してしまいます。



```
CloudShell
us-east-1

[cloudshell-user@ip-10-138-165-205 ~]$ python
Python 3.9.16 (main, Mar 28 2024, 00:00:00)
[GCC 11.4.1 20230605 (Red Hat 11.4.1-2)] on linux
Type "help", "copyright", "credits" or "license" for more information.
>>> print(0.1+0.1+0.1) # 0.3
0.30000000000000004
>>> print(2-3) # -1
-1
>>> print(-3*-2) # 6
6
>>> print(1/5) # 0.2
0.2
>>> █
```

図4.2 Pythonによる四則演算と結果出力

さて、ここで不正確な出力結果の話をしたのには理由があります。よく「AIは嘘をつく」と言われます（いわゆるハルシネーションです）。一方、コンピュータのそもそもの計算自体（この場合は足し算）が人間の意図どおりの出力をしないこともあります。しかし、だからといって、表計算ソフトを使わない人は減多にいないと思います（一般的な表計算ソフトでも同様の誤った出力をします）。なぜならほとんどの場合、実務上問題がないからです（稀に問題になります<sup>3)</sup>）。

AIも全く同じです。AIはたまに誤った出力をします。最新の情報については正確に答えられないというケースもありますし、時間経過によって誤りになってしまうケース（例えば、昔のAIであれば「AmazonのCEOはジェフ・ベゾス」と回答しますが、2024年4月現在はアンディ・ジャシーです）、さらには最初から雄弁に嘘を語るなど、いくつかのパターンがあります。「だからAIが使えない」と考えると、せっかくの恩恵に与れません。

テストと業務設計を通じて、AI利用までの壁を突破してください。嘘を減らすための工夫や、嘘をついても問題ないように、人間によるチェック体制を整えるなど、できることがあります。生成AIをビジネスに組み込むことができた会社と、できなかった会社では、ビジネスに大きな乖離が生じてまうので、工夫で乗り越えて行きましょう。

3) 問題になる場合は、Decimal型を使うなどいくつかの方法があります。

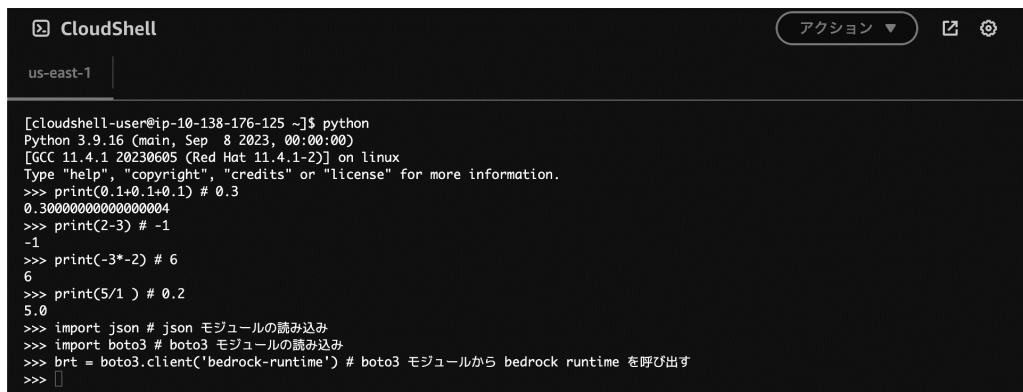
それでは、AWS SDK を使う準備をしましょう。

#### リスト4.1 AWS SDK を使うための準備

```
import json # json モジュールの読み込み
import boto3 # boto3 モジュールの読み込み
brt = boto3.client('bedrock-runtime') # boto3 モジュールから
      bedrock runtime クライアントを生成
```

まず、`import boto3`について解説します。`boto3`は正式名称をAWS SDK for Pythonといい、Pythonを使ってAWSの様々なサービスやリソースを動かし、簡単にコントロールするためのSDKです。`import boto3`というのは、`boto3`をPythonで使えるようにする準備です。続けて、`brt = boto3.client('bedrock-runtime')`と打ち込みます。`boto3`からはAWSのサービスごとにクライアントを呼び出す必要があり、それを`brt = boto3.client('bedrock-runtime')`で表現しています。

以降、`brt`で生成AIを呼び出します。冒頭を飛ばしてしまいましたが、`bedrock`のレスポンスはJSON形式で返されますので、JSONを扱うために`import json`して、JSON文字列をPythonで扱うためのモジュールを呼び出しています。次項以降は、ここまでの準備が整っている前提で記載していきます。



```
CloudShell
us-east-1

[cloudshell-user@ip-10-138-176-125 ~]$ python
Python 3.9.16 (main, Sep  8 2023, 00:00:00)
[GCC 11.4.1 20230605 (Red Hat 11.4.1-2)] on linux
Type "help", "copyright", "credits" or "license" for more information.
>>> print(0.1+0.1+0.1) # 0.3
0.30000000000000004
>>> print(2-3) # -1
-1
>>> print(-3*-2) # 6
6
>>> print(5/1) # 0.2
5.0
>>> import json # json モジュールの読み込み
>>> import boto3 # boto3 モジュールの読み込み
>>> brt = boto3.client('bedrock-runtime') # boto3 モジュールから bedrock runtime を呼び出す
>>> 
```

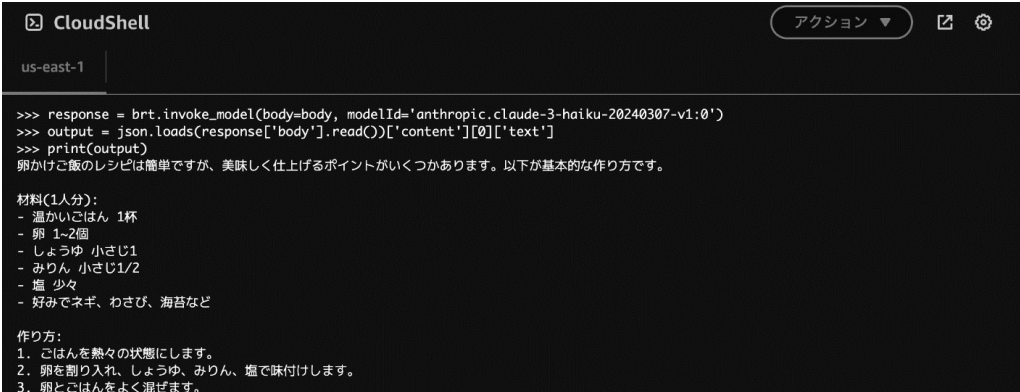
図4.3 AWS SDKを使うための準備(CloudShell画面)

## 4.4.2 Claude 3でテキスト生成

準備が整ったので、さっそくテキストを生成してみましょう。先ほどは仕事の相談をしました  
が、今度は「卵かけご飯」のレシピを訊いてみましょう。先ほどの続きで、以下のテキストを入力  
してください。

### リスト4.2 Claudeによるテキスト生成の例(その1)

```
body=json.dumps({
    'anthropic_version': 'bedrock-2023-05-31',
    'max_tokens': 4096,
    'system': '以下はユーザーと優秀なAIアシスタントのやりとりです',
    'messages': [{ 'role': 'user', 'content': '卵かけご飯のレシピを教えてください' }],
})
response = brt.invoke_model(body=body, modelId='anthropic.claude-3-
    haiku-20240307-v1:0')
output = json.loads(response['body'].read()['content'])[0]['text']
print(output)
```



```
CloudShell
us-east-1
>>> response = brt.invoke_model(body=body, modelId='anthropic.claude-3-haiku-20240307-v1:0')
>>> output = json.loads(response['body'].read()['content'])[0]['text']
>>> print(output)
卵かけご飯のレシピは簡単ですが、美味しく仕上げるポイントがいくつかあります。以下が基本的な作り方です。

材料(1人分):
- 温かいごはん 1杯
- 卵 1~2個
- しょうゆ 小さじ1
- みりん 小さじ1/2
- 塩 少々
- 好みでネギ、わさび、海苔など

作り方:
1. ごはんを熱々の状態にします。
2. 卵を割り入れ、しょうゆ、みりん、塩で味付けします。
3. 卵とごはんをよく混ぜます。
```

以下のような結果が出力されました(実行する都度、結果は変わります)。

卵かけご飯のレシピは簡単ですが、美味しく仕上げるポイントがいくつかあります。以下が基本的な作り方です。

**材料(1人分)：**

- 温かいごはん 1杯
- 卵 1～2個
- しょうゆ 小さじ1
- みりん 小さじ1/2
- 塩 少々
- 好みでネギ、わさび、海苔など

**作り方：**

1. ご飯を熱々の状態にします。
2. 卵を割り入れ、しょうゆ、みりん、塩で味付けします。
3. 卵とごはんをよく混ぜます。
4. お好みでネギ、わさび、海苔などをトッピングします。

**ポイント：**

- 温かいごはんを使うことで卵がよく絡み、なめらかな食感になります。
- 卵の量は好みで1～2個が目安です。
- しょうゆ、みりん で味付けするのがおいしいポイントです。
- トッピングで彩りや風味をプラスするとさらに美味しくなります。

気分に合わせて好みの具材を加えたり、作り方を調整してみてください。簡単でおいしい卵かけご飯が楽しめると思います。

※上の例では、見やすくなるよう一部太字にしていますが、実際の出力は書式のないプレーンテキストです。

期待どおり、卵かけご飯の作り方を教えてください(この作り方が美味しいかは知りません)。コードについて解説すると、肝は'system'と'messages'の部分です。

systemはシステムプロンプトといい、会話やAIの役割を与えるための設定です。設定しなくても動かすことはできますが、ほしい回答をAIから得るには重要ですので、AIに考えてほしいことが決まっている場合は記述するといいでしょう(ちなみに、前節のようにマネジメントコンソールから実行する場合は設定なしです)。

例えば、何かのテキストを単に和訳したい場合は、システムプロンプトに「翻訳したいユーザーと、翻訳スペシャリストAIのやりとりです。ユーザーはテキストを与えるので、AIは与えられたテキストを日本語に訳してください」と入力すると、ユーザーがテキストを与えるだけで和訳結果を返してくれるようになります。

一方、messagesはユーザーがAIに与える指示です。前節では仕事の相談をしましたが、今回は「卵かけご飯の作り方を教えてください」という指示を与えました。システムプロンプトで翻訳という役

割を与えている場合、messagesに「This is a pen.」とだけ与えれば、AIは「これはペンです。」とだけ返すようになります。systemとmessageを変えて、いろいろ試してみてください。

このようにして、プログラムから生成AIを呼び出せることを確認しましたが、さらに会話を続けることもできます。例えば、お薦めの卵のブランドを訊いてみましょう。以下のようにコードを続けて書くと、質問を追加することができます。

#### リスト4.3 Claudeによるテキスト生成の例(その2)

```
body=json.dumps({
    'anthropic_version': 'bedrock-2023-05-31',
    'max_tokens': 4096,
    'system': '以下はユーザーと優秀なAIアシスタントのやりとりです',
    'messages': [
        {'role': 'user', 'content': '卵かけご飯のレシピを教えてください'},
        {'role': 'assistant', 'content': output}, # 追加
        {'role': 'user', 'content': 'お薦めの卵のブランドを教えてください'}, # 追加
    ],
})
response = brt.invoke_model(body=body, modelId='anthropic.claude-3-
    haiku-20240307-v1:0')
output = json.loads(response['body'].read())['content'][0]['text']
print(output)
```

先ほどと違うのは、messagesに会話の履歴を入れていることです（outputという変数に、先ほどのAIの出力が格納されています）。こうすることで、過去の会話履歴を反映させた結果を出力させることができます。出力の例は以下のとおりです（実行する都度、結果は変わります）。

卵かけご飯には新鮮で良質な卵が重要です。おすすめのブランドを紹介します。

##### ● 平飼い卵

鶏が広い空間で自由に育つ平飼い卵は、卵黄が濃厚でコクがあります。有機飼料を食べた鶏が産む卵がおすすめです。有名ブランドに「小豆島卵」「みやき卵」などがあります。

##### ● 純国産卵

国産鶏のみで作った純国産卵は、卵黄が鮮やかな黄色で、しっかりとした味わいです。「赤卵」「茨城県産卵」「越後卵」などがあります。

● **放し飼い卵**

自然の中で自由に育った鶏が産んだ放し飼い卵は、深みのある味わいが特徴です。「大山鶏卵」「岡山県産卵」などがあります。

● **有機栽培卵**

有機飼料で育てた鶏の卵は、化学肥料や農薬不使用なので安心・安全です。「オーガニック卵」などのブランドがあります。

これらのブランド卵は、スーパーやネット通販などで入手できます。新鮮さと品質が高いため、卵かけご飯にぴったりです。お好みのブランドを見つけてみてくださいね。

※上の例では、見やすくなるよう一部太字にしていますが、実際の出力は書式のないプレーンテキストです。

今回の質問には「卵かけご飯」と入れていないのに、しっかりと卵かけご飯に合う卵のブランドを教えてくださいました。

もちろん画像を解説させることもできます。詳細は割愛しますが、下記の Multimodal prompts を参考にして、ぜひ試してみてください。

- URL : <https://docs.aws.amazon.com/bedrock/latest/userguide/model-parameters-anthropic-claude-messages.html>



# 4.5 アプリケーションでの利用例とユースケース

前節では、Amazon BedrockのAPIを利用して生成AIを使う方法を紹介しました。本節では、実際にAmazon BedrockのAPIを利用したアプリケーションの例を通じて、生成AIのユースケースを紹介します。

## 4.5.1 Generative AI Use Cases JPとは？

Amazon Bedrockを用いた生成AIアプリケーションはいくつか公開されていますが、ここではAWSジャパンのソリューションアーキテクトが中心となって開発した日本語のアプリケーションを紹介します(実は筆者も開発メンバーの1人だったりします)。

そのアプリは、Generative AI Use Cases JP、略称GenU (<https://github.com/aws-samples/generative-ai-use-cases-jp>) という名前でGitHub上で公開されており、MIT-0ライセンスでの商用利用が可能です。GenUはAWSのアカウントを持っていればすぐにデプロイして利用を開始でき

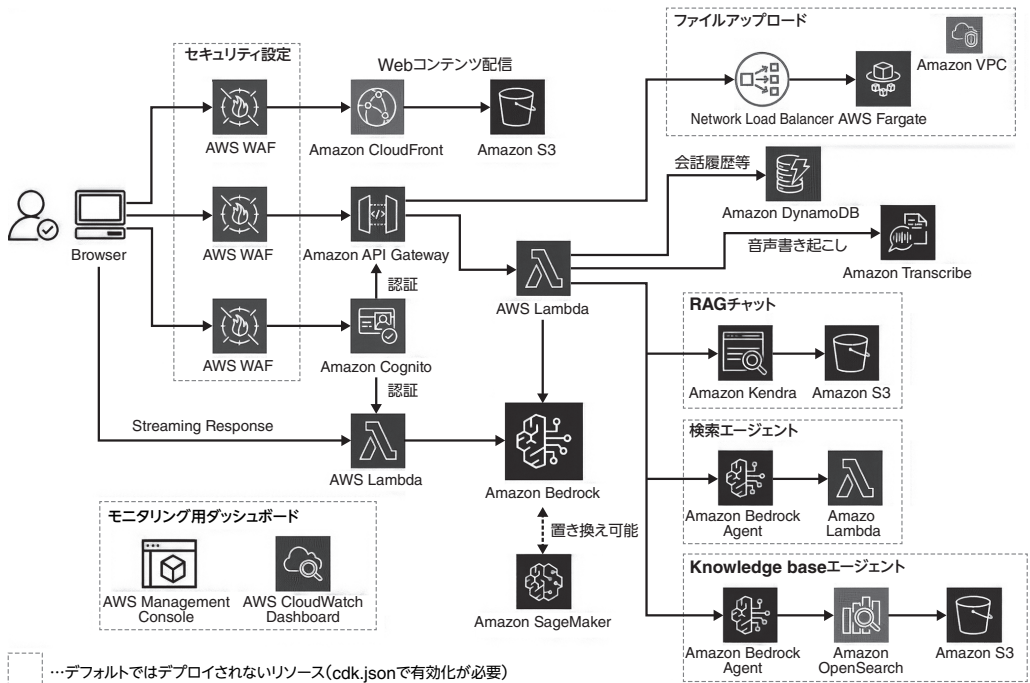


図4.4 Generative AI Use Cases JPのアーキテクチャ

るWebアプリケーションです。

このアプリケーションはユースケースにフォーカスして作りました。チャットや文書生成、翻訳、画像生成など、さまざまな用途を簡単に試せます。

ユースケースに応じたソリューションとして、自身のAWSアカウントでデプロイして使用するものであり、社内のユーザーへ簡単に展開できます。標準（デフォルト設定）だと、Amazon Cognitoという認証サービスを使ってセキュアに利用できます。さらにオプションで、AWS WAFというWebアプリケーションファイアウォールのサービスを被せることもでき、アクセスする地域やIPアドレスを絞ることもできます。

## 4.5.2 Generative AI Use Cases JPの機能

まず、生成AIでよく使われる機能として「チャット」が上げられます。Generative AI Use Cases JPを使うと、先ほどのマネジメントコンソールで行ったようなチャットをすぐに利用できます。



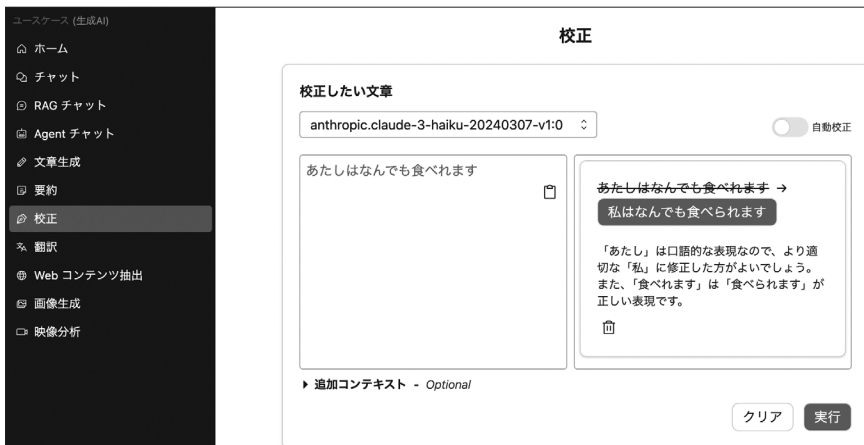
また、既存の文書を望むとおりに改変したいこともあるでしょう。そんなときは「文書生成」を使うとよいでしょう。ドッグワードの除去や、話し言葉をビジネス文書へ変換するなど、適切な指示を与えればできることは広いです。



生成 AI は文章の「要約」にもよく使われます。長い文章を読む前に、その文章に読む価値があるのかを知りたいときなどに便利です。



ほかにも、自分が書いた文章に間違いがないか、チェックしてもらいたいときもあるでしょう。そんなときは「校正」を使うと、誤字や文章の誤りを指摘し、修正内容を提案してくれます。



先述のとおり、生成AIは翻訳によく使われます。生成AIを使わない従来の機械翻訳の場合、サービス名などの固有名詞に一般的な単語が使われているとそのまま訳してしまうなど、不自然な結果が出る場合があります（例えば「Amazon Connect」を「Amazon 接続」と翻訳してしまうなど）。生成AIは文脈を判断して、固有名詞をそのまま出力するなど、気の利いた翻訳をしてくれるところが利点です。



## ●異なる生成AI同士を組み合わせる

画像生成では、異なる生成AIを組み合わせて使うことができます。

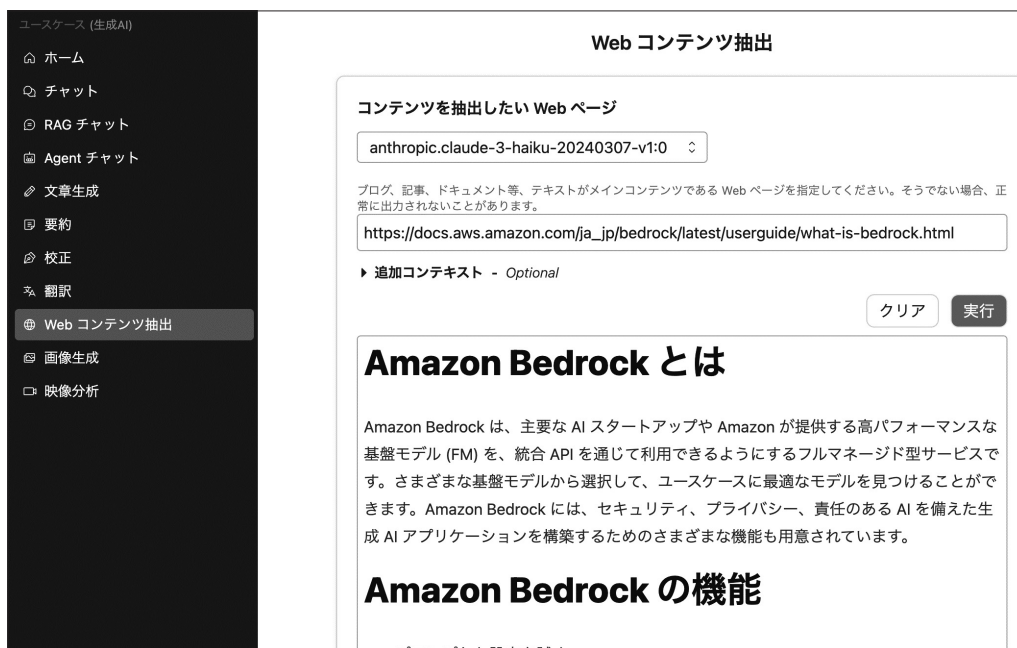
4.2節末尾の画像生成では、プロンプトの中で「glass bottle, grapes juice, white table, blue sky, sun」と、英語でマネジメントコンソールに入力しました。生成したい画像の特徴を、カンマ区切りで箇条書きにした、あまり馴染みのないテキストでした。画像生成をするモデルでは一般的な入力の仕方ではありますが、初見の方は戸惑います。

そこで、プロンプトを生成AIに出力させて、そこから画像を生成させるというやり方が可能です。日本語で「ゴールデンレトリバーとチワワのミックスが、天気のよい海を楽しく泳いでいる」と入力すると、「golden retriever, chihuahua mix, swimming, sunny beach, ocean, happy, playful」という画像生成用のプロンプトが生成され、日本語で指示したとおりの画像が生成されます。

このスクリーンショットは、AI画像生成アプリケーションのインターフェースを示しています。左側のナビゲーションメニューには「ホーム」、「チャット」、「RAG チャット」、「Agent チャット」、「文章生成」、「要約」、「校正」、「翻訳」、「Web コンテンツ抽出」、「画像生成」、「映像分析」があります。中央のチャット形式で画像生成のセクションには、モデル名「anthropic.claude-3-haiku-20240307-v1:0」が設定されています。チャット履歴には、日本語のプロンプト「ゴールデンレトリバーとチワワのミックスが天気が良い海を楽しく泳いでいる」があり、生成された犬の画像が示されています。右側の設定パネルには、「プロンプト」欄に「golden retriever, chihuahua mix, swimming, sunny beach, ocean, happy, playful」が設定されており、「ネガティブプロンプト」欄には「ugly, deformed, disfigured, poorly drawn, extra limbs, mutated, extra fingers, monstrous」が設定されています。また、「stability.stable-diffusion-xl-v1」モデルが選択されており、「Seed」が「2428494327」、「画像生成数」が「3」に設定されています。下部には「生成」と「クリア」のボタンがあります。

生成AIを複数組み合わせるアイデアはほかにもあります。

「Web コンテンツ抽出」という機能を使うと、Webサイトのメインコンテンツ（例えばニュースサイトから広告や他のリンクを除去したニュースの本文）だけを抽出できます。ニュースサイトのニュース記事を要約しようと思っても、記事のテキストだけを選択しようとしても、一発では難しく、コピー&ペーストを繰り返すことがあります。Webコンテンツ抽出の結果をさらに要約させれば、簡単に期待どおりの出力が得られます。あるいは、英語のコンテンツを翻訳させうえで要約させるなども便利です。



ここまでは機能をベースにしてソリューションを紹介してきましたが、実務でよくある使い方のひとつに「議事録のまとめ」があります。

会議を録音しておけば、音声ファイルが手に入ります。このソリューションではAmazon Transcribeという文字起こしのサービスも使えますので、音声をテキストに変換できます。そのテキストから、文書生成でフィルターなどを除くのはもちろん、決定事項などを抜き出せば、ほぼ自動で議事録を作成できます。

このように、できることはアイデア次第で広がります。生成AIは産まれて間もないものでもあるので、ぜひ皆さんは既存のアイデアを利用しつつ、新しいビジネスでの利用を發明してください。

# 結びにかえて

---

「AIが前提の世の中では、自分が努力し勉強してきた技術が無駄になるのではないかと聞かれることがあります。この質問は、かな漢字変換が「AI変換」と呼ばれていた30年近く前から、AIが流行る度に何度も聞かれました。その当時は「漢字の読み書きができなくなる」と真剣に議論され、技術者は各社の漢字変換エンジンの良し悪しを大真面目に比較していました。生成AIのモデルを侃々諤々議論していた昨今に少し似ています。

他方、テクノロジーのライフサイクルは明らかに短くなりました。例えばガソリンエンジンのように、技術が磨かれながら時間をかけて徐々に世の中に浸透していった時代から、スマホのアプリのように、世界中どこでもほぼ同時に新しい技術が手に入る時代になりました。今はエンジニアでなくても、好奇心さえあれば誰でも、生成AIを利用してプログラムコードを書いたり、SQL文でデータ分析を行ったりできます。

一方、企業は市場で生き残るために、他社と差別化せねばなりません。どの企業も真似できる画一的な生産性向上にAIを適用するだけでは、差別化要因にはなりません。何より個々の企業が積み重ねてきた努力や仕事は十人十色です。他社と異なるデータを使い、自社に有益な入力から、世の中と異なる出力を得ることで小さな差異が生まれます。生成AIと言ってもAIであり、AIはデータで育ちます。如何にして自社の仕事ならではのデータを吸い上げたり、合成して足したりして差異を発生させ、人知れず業務にAIを内蔵するか、私たちは非常に自由度の高い時代を生きています。

やがてAIが世の中に浸透すると、もうAIとは呼ばれなくなります。インターネットの普及からスマホの誕生までは約20年かかりましたが、生成AIが生成AIと呼ばれなくなるまでの時間はもっと短いと予想されています。日本ではあと数年のうちに、プログラム必修教育を受けた若い世代が社会に出てきます。先に大人になった私達が豊かなデータを整備しておけば、若い世代のAIが自由に価値を生み出すことができます。今まさに、この本を読んでいる皆さんの努力と勉強が、今の時代と次の世代に必ず役に立つと確信しています。

2024年6月 著者を代表して **黒川 亮**

# AWSの生成AI

一社一社の課題に応える3階建てのクラウドサービス【ダイジェスト版】

黒川 亮・呉 和仁 [共著]

アマゾン ウェブ サービス ジャパン合同会社 [監修]

非売品

©アマゾン ウェブサービス ジャパン合同会社 2024

発行日: 2024年6月20日

発行元/お問い合わせ先: アマゾン ウェブサービス ジャパン合同会社 AI/ML事業部

〒141-0021 東京都品川区上大崎3丁目1-1

URL: <https://aws.amazon.com/jp/>

制作協力: 株式会社リックテレコム 書籍出版部 URL: <https://www.ric.co.jp/>

※不許無断複製