



金融サービス業界でデータの価値を大きく引き出す



: 金融サービス業界でデータの価値を大きく引き出す

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

Amazon の商標およびトレードドレスは Amazon 以外の製品およびサービスに使用することはできません。また、お客様に誤解を与える可能性がある形式で、または Amazon の信用を損なう形式で使用することもできません。Amazon が所有していないその他のすべての商標は Amazon との提携、関連、支援関係の有無にかかわらず、それら該当する所有者の資産です。

Table of Contents

序章	1
ターゲットを絞ったビジネス成果	2
運用メトリクス	4
ソリューションの概要	7
スケーラブルな ML フレームワーク	7
メタデータの中央ハブ	9
SageMaker 検証	10
ベストプラクティス	11
成功のビジョン	13
よくある質問	14
次の手順	16
リソース	17
ドキュメント履歴	18
.....	xix

金融サービス業界でデータの価値を大きく引き出す

Brian Cavanagh、Maira Ladeira Tanke、Amine Ait el harraj、Junaid Baba、Maren Suilmann、Pauline Ting、Sokratis Kartakis (Amazon Web Services (AWS))

2022 年 9 月 ([ドキュメント履歴](#))

金融サービス (FS) 業界は、銀行のデジタルトランスフォーメーションを先導する金融テクノロジー企業 (フィンテック) やデジタル銀行による大きな混乱に直面しています。このトランスフォーメーションは、人工知能と機械学習 (AI/ML) 技術に基づく銀行商品やサービスの開発によって、ますます特徴付けられるようになっていきます。McKinsey & Company の「[AI-bank of the future: Can banks meet the AI challenge?](#)」によると、金融機関が今日的であり続けるためには、AI/ML テクノロジーを大規模にデプロイする必要があります。AI/ML テクノロジーを大規模にデプロイするには、金融機関はまずデータのビジネス価値を引き出す必要があります。

金融機関は膨大な量のデータを保有していますが、そのデータの価値を大きく引き出すのには苦労しています。データから価値を引き出すことで、顧客やパートナーに、深くまで踏み込んでパーソナライズされたサービス、インサイト、サポートを提供できるようになります。引き出された価値は、金融機関が資本市場から製造業務に至る現行のプロセスの非効率性を迅速に明らかにし、最適化が必要な分野について優先順位付けされたインサイトを得るのにも役立ちます。本書では、組織内で ML 機能を開発することで、データの価値を大きく引き出す方法を説明しています。本書の対象読者には、銀行および資産管理業界の CEO、CFO、CIO、上級管理職が挙げられます。

本書で解説する戦略によって、以下のことを理解できるようになります。

- 組織に ML 機能を導入することで得られるビジネス成果
- 運用を成功させるためのメトリクスと目標スコア
- 組織の ML 機能を変革するためのスケーラブルな ML フレームワーク
- AWS スケーリングのベストプラクティス (数百のお客様の実装に基づく)

ターゲットを絞ったビジネス成果

重要なビジネス成果とは、組織のデータをビジネス価値に変えることができる最適化されたプロセスを導入することです。具体的には、この戦略を通じて、次のようにターゲットを絞ったビジネス成果を達成できます。

- 機械学習と運用 (MLOps) の機能を組織全体にスケールし、数百人のデータサイエンティストやデータエンジニアが、組織内で ML ワークフローを実行できるよう支援する ML プラットフォームを開発します。
- AWS Service Catalog を使用して Amazon SageMaker AI でオンデマンドのマネージドインフラストラクチャを作成することで、スケーラブル、セキュア、コスト効率が高く、持続可能なインフラストラクチャのデプロイを実装します。
- ML モデルの開発とデプロイプロセスを複数のチームで標準化します。
- 既存のモデルの技術的負担を軽減し、再利用可能なアーティファクトを作成することで、将来的なモデル開発を加速させます。
- データや分析のユースケースでアイデアが価値を生むまでの期間を 12～16 週間に短縮します。
- ML ユースケース環境の作成時間を 1～2 日に短縮します。

企業内でアドバンストアナリティクスの利用をスケールすると、ML モデルやソリューションを開発して本番稼働環境にリリースするまでに時間がかかりすぎる場合があります。と提携することで AWS、ビジネスと顧客をサポートする ML ベースのサービスを開発および実稼働化するための、最新で安全でスケーラブルで持続可能なセルフサービスプラットフォームを迅速に設計、構築、起動するのに役立つガイダンスとサポートを受けることができます。[AWS プロフェッショナルサービス](#) はお客様と協力して、[SageMaker AI](#) を使用して組織のニーズに合わせてカスタマイズされたユースケース用の ML モデルを構築、トレーニング、デプロイするための AWS ベストプラクティスの実装を加速できます。

このコラボレーションにより、次のことが可能になります。

- インフラストラクチャとアプリケーションコードに対する、統合されたセルフサービスの DevOps 主導型アプローチなら、デプロイまでのルートが明確なため、デプロイ時間を数週間から数分に短縮可能
- 業界のベストプラクティスと銀行全体で共有されるアーティファクトを活用した ML モデルおよびインサイトにより、イノベーションを加速させる、安全で制御されテンプレート化された環境
- 組織全体で、より簡単で一貫したデータのアクセスと共有が可能

- コンピューティング要件を最小限に抑え、コストを削減し、持続可能な機械学習の開発と運用を可能にするオンデマンドのマネージドアーキテクチャに基づく最新のツールセット。継続的なユースケースとコンプライアンス要件を満たすために、新しい AWS 製品やサービスに柔軟に対応できます。
- 組織のデータサイエンスチームとエンジニアリングチームが自力で取り組み、組織全体で ML 製品をスケールできるようにするための導入、エンゲージメント、トレーニングのサポート

運用メトリクス

AWS プロフェッショナルサービスは、社内チームと協力して、以下の表で定義されている運用メトリクスに照らして組織の進捗状況を追跡するためのデリバリーガバナンスメカニズムを確立できます。メトリクスは現実世界の値に基づいており、MLOps エンゲージメントを定義しやすくします。次のテーブルの値はガイドラインにすぎません。目標値は組織の実装によって異なります。

[面積]	サブエリア	メトリクス	プラットフォームローンチからの 6 か月目標
1. 運用効率	高速配信	タイムトゥバリュー	平均 3 か月
	事業部門への明確なコスト配分によるコストの透明性	AWS 管理コスト	初期値未満
2. バウンダリレス配信	制御された方法で付与された、シームレスにアクセスできる自由	アクセスにかかる時間	1 日
	CI/CD サポート	タイムトゥバリュー (アイデアをかたちに する)	平均 3 か月
	ルートトゥライブ配信の簡略化	デプロイまでの時間 (ベータ版以降)	平均 3 か月
	オンデマンドラボのスピンアップ/スピンドウン	環境のスピンアップにかかる時間	24 時間
3. 制御	各ユースケースに合わせて調整され、動的に付与または削除されるアクセス	ユースケースへのアクセスにかかる時間	< 1 日

	スポーク主導型の開発から稼働までを可能にする、永続的な本番稼働環境	デプロイするまでの時間	2 週間
	使用時点で管理され、コストセンターに帰属するストレージおよびコンピューティングのコスト	実績値/予測値の透明性	許容される予測精度の差異
	内部セキュリティ基準の遵守 (自動評価と監査)	非準拠環境の数	0
	(SLA の範囲内で) データの提供および共有の責任を負うデータ所有者	データレイク内のデータのコピー	データレイクにあるデータのコピーは 0
	規制に基づくデータ分離をサポートする一般的な処理	コンプライアンスに準拠したアクセス	規制検出結果は 0
4. 絶えず進化する反復可能なパターン	標準が絶えず進化するモデル開発環境	1 年あたりの更新数	6
	スポークを使用して環境を自由にパッケージ化してデプロイする能力	環境のスピンアップにかかる時間	2 時間
	利用中のサービスとインフラストラクチャの明確なレイアウト	追跡されないインフラストラクチャ	0
5. すべての銀行向け	異なるモデリング環境数の減少	環境数	< 2

組織の境界を越えた チームコラボレーショ ンの簡素化	アクセスにかかる時間 (データなど)	1 日
共通かつ単一のオペ レーティングモデル/ フレームワーク	モデルによって制御さ れるドメイン数	> 3

ソリューションの概要

スケーラブルな ML フレームワーク


何百万人もの顧客が複数の事業部門に分散している企業でビジネス価値を引き出すためには、ML ワークフローで、サイロ化されたチームが所有および管理するデータを、さまざまなツールを使用して統合する必要があります。銀行は顧客データの保護に力を入れています。同様に、ML モデルの開発で使用するインフラストラクチャにも、高いセキュリティ基準が適用されます。このようなセキュリティ強化によってさらに複雑さが増し、新しい ML モデルのタイムトゥバリューに影響します。スケーラブルな ML フレームワークでは、最新の標準化されたツールセットを使用することで、さまざまなツールを組み合わせる手間が省け、新しい ML モデルの運用開始までのプロセスを簡素化できます。

従来、FS 業界におけるデータサイエンス活動の管理とサポートは、組織全体のデータチームの要件収集、リソースの提供、インフラストラクチャの維持を行う中央プラットフォームチームによって管理されています。組織全体の連合チームで ML の利用を迅速にスケールするために、スケーラブルな ML フレームワークを使用すれば、新しいモデルやパイプラインの開発者にセルフサービス機能を提供できます。これにより、開発者は事前に承認され、標準化された最新の安全なインフラストラクチャをデプロイできます。最終的には、このようなセルフサービス機能により、組織は一元化されたプラットフォームチームへの依存を減らし、ML モデル開発のタイムトゥバリューを短縮できます。


スケーラブルな ML フレームワークにより、データコンシューマー (データサイエンティストや ML エンジニアなど) が以下をできるようになることで、ビジネス価値を引き出すことができます。

- モデルトレーニングに必要な、事前に承認されたデータを参照して見つける
- 事前に承認されたデータにすばやく簡単にアクセスできる
- 事前に承認されたデータを使用してモデルの実行可能性を証明する
- 実証済みのモデルを本番稼働環境にリリースし、他のユーザーが使用できるようにする

次の図は、フレームワークのエンドツーエンドのフローと、ML ユースケースの運用開始までの簡略化されたルートを示しています。



広い意味では、データコンシューマーは data.all と呼ばれるサーバーレスアクセラレーターを使用して複数のデータレイクにまたがるデータを調達し、そのデータを使用してモデルをトレーニングします。これを次の図に示します。



下位レベルでは、スケーラブルな ML フレームワークには次のものが含まれます。

- セルフサービスインフラストラクチャのデプロイ — 一元化されたチームへの依存を軽減します。

- 中央の Python パッケージ管理システム — 事前に承認された Python パッケージをモデル開発に使用できるようにします。
- モデル開発とプロモーションのための CI/CD パイプライン — 継続的インテグレーションと継続的 (CI/CD) パイプラインを Infrastructure as Code (IaC) テンプレートの一部として組み込むことで、稼働までの時間を短縮します。
- モデルテスト機能 — 新しいモデルで自動的に利用できるユニットテスト、モデルテスト、インテグレーションテスト、エンドツーエンドテストの機能を活用できます。
- モデルのデカップリングとオーケストレーション – Amazon [Amazon SageMaker AI Pipelines](#) を使用して、計算リソースの要件とさまざまなステップのオーケストレーションに従ってモデルステップをデカップリングすることで、不要なコンピューティングを回避し、デプロイをより堅牢にします。
- コード標準化 — [Python Enhancement Proposal \(PEP 8\)](#) の標準を検証するために、CI/CD パイプライン統合を使用してコードの品質向上を図ります。
- 汎用 ML テンプレートのクイックスタート – デプロイに [SageMaker AI プロジェクト](#) を使用して、ボタンをクリックするだけで ML モデリング環境 (開発、本番前、本番稼働) と関連するパイプラインをインスタンス化する Service Catalog テンプレートを取得します。
- データおよびモデル品質のモニタリング – [Amazon SageMaker AI Model Monitor](#) を使用してデータとモデル品質のドリフトを自動的にモニタリングすることで、モデルが運用要件とリスク許容レベルに従って動作していることを確認します。
- バイアスモニタリング — データの不均衡や、世界の変化によってモデルにバイアスが生じていないかを自動的にチェックすることで、モデル所有者が公正かつ公平な意思決定を行えるようにします。

メタデータの中央ハブ

[data.all](#) は、既存の AWS データレイクと統合してメタデータを中央ハブに集めることのできるサーバーレスアクセラレータです。data.all のシンプルで使いやすい UI には、複数ある既存のデータレイクから、データセットに関連するメタデータが表示されます。これにより、技術系以外のユーザーと技術系のユーザーのいずれも、ML ラボで利用できる貴重なデータの検索、閲覧、アクセスのリクエストができるようになります。Data.all は AWS Lake Formation、AWS Lambda Amazon Elastic Container Service (Amazon ECS) AWS Fargate、Amazon OpenSearch Service、および使します AWS Glue。

SageMaker 検証

さまざまなデータ処理と ML アーキテクチャにわたって SageMaker AI の機能を証明するために、機能を実装するチームは、銀行リーダーシップチームとともに、銀行の顧客のさまざまな部門からさまざまな複雑さのユースケースを選択します。ユースケースデータは難読化され、機能検証フェーズのユースケース開発アカウントのローカル Amazon Simple Storage Service (Amazon S3) データバケットで利用できます。 [Amazon S3](#)

元のトレーニング環境から SageMaker AI アーキテクチャへのモデル移行が完了すると、クラウドホストデータレイクによって、本番モデルによるデータの読み取りが可能になります。本番モデルによって生成された予測は、データレイクに書き戻されます。

候補となるユースケースが移行されると、スケーラブルな ML フレームワークがターゲットメトリクスの初期ベースラインを作成します。スケーラブルな ML フレームワークによって時間短縮が可能になったことの証拠として、ベースラインを過去のオンプレミスや他のクラウドプロバイダーのタイミングと比較できます。

ベストプラクティス

このセクションでは、MLOps の AWS ベストプラクティスの概要を説明します。

アカウントの管理と分離

アカウント管理の[AWS ベストプラクティス](#)では、ユースケースごとに 4 つのアカウントにアカウントを分割することをお勧めします。実験、開発、テスト、製品です。また、組織全体で MLOps リソースを共有するためのガバナンスアカウントと、一元的なデータアクセスを提供するためのデータレイクアカウントを用意することもベストプラクティスです。その理由は、開発、テスト、本番稼働環境を完全に分離すれば、複数のユースケースやデータサイエンスチームが同じアカウントセットを共有することで生じるサービスの制限による遅延を回避し、各ユースケースのコストの概要を完全に把握できるからです。最後に、各ユースケースには独自のアカウントセットがあるため、アカウントレベルのデータを分離するのがベストプラクティスです。

セキュリティ標準

セキュリティ要件を満たすには、公共のインターネットアクセスを無効にし、すべてのデータをカスタムキーで暗号化するのがベストプラクティスです。その後、Service Catalog を使用して、Amazon SageMaker AI Studio の安全なインスタンスを開発アカウントに数分でデプロイできます。SageMaker AI プロジェクトでデプロイされたテンプレートを通じて SageMaker AI を使用することで、各ユースケースの監査機能とモデルモニタリング機能を取得することもできます。

ユースケース機能

アカウントのセットアップが完了すると、組織のデータサイエンティストは SageMaker AI Studio で SageMaker AI プロジェクトを使用して新しいユースケーステンプレートをリクエストできます。このプロセスでは、CI/CD パイプライン、ユニットテスト、モデルテスト、モデルモニタリングなどの MLOps 機能を (中央チームからの最小限のサポートで) 開発アカウントに組み込むために必要なインフラストラクチャをデプロイします。

次に、実験追跡、モデルの説明可能性、バイアス検出、データ/モデル品質モニタリングなどの SageMaker AI SageMaker AI アーキテクチャで実行する各ユースケースが開発 (または既存のアプリケーションコードベースの場合はリファクタリング) されます。これらの機能を各ユースケースパイプラインに追加するには、SageMaker AI Pipelines の[パイプラインステップ](#)を使用します。

MLOps 成熟度ジャーニー

MLOps 成熟度ジャーニーでは、エンドツーエンドのモデルワークフローを確実に実施するために、全社的な設定で利用可能となる必須の MLOps 機能を定義します。成熟度ジャーニーは次の 4 つの段階で構成されます。

1. 初期 — この段階では、実験用アカウントを作成します。また、SageMaker Studio やその他の新しい AWS サービスを試すことができる組織内の新しい AWS アカウントも保護します。
2. 繰り返し可能 — この段階では、コードリポジトリと ML ソリューション開発を標準化します。また、マルチアカウント実装アプローチを導入し、提供タイプをスケールアウトする際にモデルガバナンスとモデル監査をサポートするよう、コードリポジトリを標準化します。ガバナンスアカウントが提供する標準ソリューションを使用して、本番稼働環境に対応したモデル開発アプローチを導入するのがベストプラクティスです。データはデータレイクアカウントに保存され、ユースケースは 2 つのアカウントで開発されます。1 つ目のアカウントは、データサイエンス探索期間中の実験用です。このアカウントで、データサイエンティストはビジネス上の問題を解決するためのモデルを発見し、複数の可能性を試します。もう 1 つのアカウントは開発用で、最適なモデルが特定され、データサイエンスチームが推論パイプラインで作業する準備が整った後に開発が行われます。
3. 信頼できる — この段階では、テスト、デプロイ、マルチアカウントデプロイを導入します。MLOps の要件を理解し、自動テストを導入する必要があります。MLOps のベストプラクティスを実装して、モデルが堅牢かつ安全であることを確認しましょう。このフェーズでは、2 つの新しいユースケースアカウントを導入します。1 つは本番稼働環境をエミュレートする環境で開発されたモデルをテストするためのテストアカウント、もう 1 つは事業活動中にモデル推論を実行するための本番稼働アカウントです。最後に、マルチアカウント設定でモデルのテスト、デプロイ、モニタリングを自動化して、設定した高い品質とパフォーマンスの基準をモデルが満たしていることを確認します。
4. スケーラブル — この段階では、複数の ML ソリューションをテンプレート化して製品化します。エンドツーエンドのモデル構築プロセス中に、複数のチームや ML ユースケースが MLOps を導入し始めます。この段階でスケーラビリティを実現するには、より幅広いデータサイエンティストからの支援を通じてテンプレートライブラリのテンプレート数を増やし、組織全体のより多くのチームがアイデアから製品モデルまでの価値を実現するのにかかる時間を短縮して、スケールしながら反復処理を行います。

MLOps 成熟度モデルの詳細については、AWS Machine Learning Blog の[Amazon SageMaker AI を使用する企業の MLOps 基盤ロードマップ](#)」を参照してください。

成功のビジョン

データの価値を正常に引き出すには、組織は、この戦略で定義された AWS ベストプラクティスに沿ってビジネス成果を達成するスケーラブルな ML フレームワークを開発する必要があります。このようなフレームワークは、組織が以下のことを達成するのに役立ちます。

- 高度な分析、データサイエンスベースのワークロード、およびそれらのワークロードに対応する明確な DevOps 主導型の運用開始ルートを開発するための、標準化された本番稼働レベルのインフラストラクチャ作成用セルフサービスプロセス
- 合理化されたガバナンスに恵まれ、価値実現までの時間を短縮すると同時に、貴重な技術リソースも解放できるユースケースチーム
- 再利用可能な ML テンプレートにアクセスして共有するためのデータサイエンスライブラリ。テンプレートを改良して他のユーザーと共有できるテンプレートを使用することで、エンドツーエンドの配信時間を素早く短縮できます
- 複数のデータレイクにあるすべてのデータにメタデータを提供するクラウド AWS データリファレンスライブラリ (DataHub)。データ検出だけでなく、モデルのトレーニングに必要なデータにアクセスする時間を短縮します。
- プラットフォームおよび基盤となるツールキットの管理、新機能開発のサポート、主要な統制の継続的な準拠について訓練を受けた専任の DevOps チーム
- 本番稼働レベルのアカウントを通して配信される実際のユースケース
- プロジェクトチームと受入側のビジネスラインチーム (スポークチーム) 間の知識移転。これにより、ビジネスチームは継続的な開発と運用開始までのプロセスを自己管理できます
- 対象となるビジネスチームグループとの初期エンゲージメントおよび導入活動の完了
- 導入をサポートするために何百ものクラスルームベースの AWS トレーニングセッションを提供

よくある質問

MLOps プラットフォームはいつ構築すべきですか？

エンジニアが ML モデルの構築よりもツールオプションの調査と承認の取得に多くの時間を費やしていることに気づいたときが、MLOps プラットフォームで標準化するタイミングです。

他の ML ツールを MLOps プラットフォームに統合できますか？

はい。ツール以外の AWS をプラットフォームに統合できます。SageMaker AI Studio は MLOps プラットフォームの中核ですが、他の製品を SageMaker AI Studio のサービススイートと統合することはできます。

組織でガバナンス要件を簡素化してイノベーションを加速させるにはどうすればいいですか？

MLOps プラットフォームの構築を証明するために選択するユースケース候補の一部として、ユースケースが十分に複雑で、さまざまなデータ分類が必要で、大量のビッグデータが必要であることを確認してください。そうすることで、プラットフォームの機能を証明するだけでなく、最初のプラットフォームリリースの一環として、ガバナンスの観点から見た最も手間のかかる作業を行うことができます。これができれば、ロールアウトの一部として MLOps プラットフォームを導入するチームは、複雑なユースケースのガバナンス要件をすでに満たしているプラットフォームを使用するため、ガバナンスの負荷が軽減されます。

MLOps プラットフォームを構築するにはどのようなチームが必要ですか？

複数のペルソナやテクノロジー間のインタラクションを明確に定義する堅牢な MLOps 基盤があれば、タイムトゥバリューを短縮し、コストを削減し、データサイエンティストがイノベーションに集中できるようになります。MLOps プラットフォーム開発では、適切なチームを持つことが失敗と成功の分かれ目になります。MLOps の性質上、データサイエンティスト、ML エンジニア、DevOps プロフェッショナル、データ所有者、IT 所有者、ビジネスアナリスト、製品所有者など、多くの役割が関与する必要があります。MLOps プラットフォームで最良の結果が得られるように、すべてのステークホルダーが部門横断的なチームで交流するようにしてください。

MLOps ジャーニーを始めるにはどうすればいいですか？

まず、データサイエンティストがデータのスナップショットを受け取る、安全な実験環境を構築することから始められます。データサイエンティストは SageMaker AI を使用して実験し、最終的に ML が特定のビジネス上の問題を解決できることを証明できます。

MLOps トランスフォーメーションは、組織内のトップダウンアプローチとボトムアップアプローチのどちらで推進すべきでしょうか？

ボトムアップアプローチは成功する可能性があります。MLOps プラットフォーム開発の成功には経営陣のサポートが不可欠です。トップダウンアプローチでは、開発したソリューションをより迅速に標準化し、コストを削減し、組織内のさまざまなチームが開発したモデル間のスケーラビリティと再利用性を高めることができます。

次の手順

スケーラブルな ML フレームワークを導入してデータのビジネス価値を引き出すために、次のステップを検討してみましょう。

1. [AWS 販売担当者](#)または[AWS プロフェッショナルサービス担当者にお問い合わせください](#)。
2. 組織内の適切なチームメンバーを対象に、以下のようなトレーニングや認定資格を取得できる機会を設けましょう。
 - [AWS トレーニングと認定](#)
 - [での MLOps エンジニアリング AWS](#)
 - [AWS 認定ビッグデータ - 専門分野](#)
 - [AWS 認定Machine Learning - 専門分野](#)
 - [AWS 認定 DevOps エンジニア - プロフェッショナル](#)
 - [AWS プライベートトレーニング - 情報リクエスト](#)

リソース

- [Machine Learningの最新情報](#) (AWS ドキュメント)
- [SageMaker AI プロジェクトによる MLOps の自動化](#) (YouTube)
- [最もスケーラブルで信頼できる安全なクラウドでデータを機能させる](#) (AWS ドキュメント)
- [Amazon SageMaker AI を使用する企業の MLOps 基盤ロードマップ](#) (AWS Machine Learning ブログ)
- [パート 1: NatWest グループがスケーラブルで安全で持続可能な MLOps プラットフォームを構築する方法](#) (AWS Machine Learning ブログ)
- [AI-bank of the future: Can banks meet the AI challenge?](#) (McKinsey & Company)

ドキュメント履歴

以下の表は、本ガイドの重要な変更点について説明したものです。今後の更新に関する通知を受け取る場合は、[RSS フィード](#) をサブスクライブできます。

変更	説明	日付
DataHub を data.all に置き換えました。	—	2023 年 11 月 7 日
初版発行	—	2022 年 9 月 16 日

翻訳は機械翻訳により提供されています。提供された翻訳内容と英語版の間で齟齬、不一致または矛盾がある場合、英語版が優先します。