



マネー・ローンダリングおよびテロ資金  
供与対策への人工知能（AI）活用例  
機械学習技術の適用を深掘りする

# 目次

はじめに	2
コンプライアンスにおける 機械学習の可能性	4
マネー・ローンダリングとの闘いへの 機械学習の活用および適用	8
機械学習を 理解し、採用する	12
ケーススタディ	24
POC から本番運用へ：	32
この先に何があるか？	33
結論	34
巻末注	37

# 略語集

AI	— Artificial Intelligence	人工知能
AML	— Anti-Money Laundering	マネー・ローンダリング対策
CFT	— Counter Terrorist Financing	テロ資金供与対策
FCC	— Financial Crime Compliance	金融犯罪コンプライアンス
LIME	— Local Interpretable Model- Agnostic Explanations	解釈可能なモデルによる局所的な説明法
MAS	— Monetary Authority of Singapore	シンガポール金融庁
ML	— Machine Learning	機械学習
PEP	— Politically Exposed Person	重要な公的地位を有する者
POC	— Proof of Concept	概念実証
PPP	— Public-private Partnerships	官民パートナーシップ
SLA	— Service Level Agreement	サービスレベル合意書
SAR	— Suspicious Activity Report	疑わしい活動報告書
STR	— Suspicious Transaction Report	疑わしい取引報告書
SHAP	— SHapley Additive exPlanation	シャープレイ値を用いた機械学習の説明法

注意事項：本資料はDeloitte Globalが2018年に発表した内容をもとに、デロイト トーマツ グループが翻訳・加筆したものです。和訳版と原文（英語）に差異が発生した場合には、原文を優先します。執筆者肩書は原文発行当時のものです。

## はじめに

マネー・ローンダリング（資金洗浄）との闘いは極めて大きな課題であり、相当なコストや、規制、評判、金融犯罪などのリスクが伴います。

このようなリスクの管理は金融システムの番人たちに委ねられています。また、犯罪者は洗浄テクニックを進化させ続け、システムの抜け穴を見つけては資金移動のために悪用しています。


このような犯罪者は、インターネットバンキング、電子決済、暗号通貨などの新たなテクノロジーを使って、不正資金を驚異的なスピードで越境移動させることもできます。これにより取引の複雑化、重層化、即時化が進み、従来のアプローチでは監視や検知が難しくなっています。

犯罪活動の中心にいるのは、不正資金を正規の金融システムを介してシームレスに移動させる能力を備えた巧妙なマネー・ロンダラーです。マネー・ロンダラーは巧妙で、世界中の金融機関を深刻な脅威にさらしており、その活動は社会にも破壊的な結果をもたらします。その結果、テロ、麻薬、人身売買などの社会悪が、社会構造や秩序、社会ガバナンス、オープンで公正な商取引を脅かします。このような理由から、組織の金融取引のモニタリングおよびネームスクリーニングの実効性を継続的に向上させることは、デジタル時代ではかつてないほど決定的に重要になっています。

シンガポールは、世界4大<sup>1</sup>金融センターのひとつとして、このようなマネー・ローンダリングの脅威の矢面に立たされています。国家として、シンガポールは、新たなマネー・ローンダリングの脅威から逃れられません。事実、同国はこのように進化する「脅威動向」への対処に関して、革新的なイニシアチブ、ソリューション、フォーラムにより先導的な役割を担ってきました。シンガポール金融庁（MAS）が恒例イベントとして開催する「シンガポール・フィンテック・フェスティバル」はその一例です。

これまで以上に、業界と規制当局は継続的に監視を強化する必要があります。さもなければ、「脅威動向」のリスクを取り違えることとなるでしょう。今後のマネー・ローンダリングおよびテロ資金供与リスクとの闘いにおいては、官民パートナーシップ（PPP）の可能性を生かしたエコシステム主導型の戦略が前進のための重要な一歩となるでしょう。実際、ユナイテッド・オーバーシーズ銀行（UOB）などの銀行は、エコシステム内の様々なプレイヤーと協働してマネー・ローンダリング対策を講じています。その事例として、この白書では、機械学習ソリューションの共同開発行程に関するケーススタディを取り上げています。

さしあたっては、PPPのメリットと最大の可能性を実現するために緊密な関係を構築しつつ、イノベーションと新たなテクノロジーを取り入れることが規制リスクの管理を向上させるための最善の策です。

The background of the page features a complex, abstract design of swirling, glowing blue lines against a dark, almost black background. The lines form a sense of motion and depth, creating a futuristic and dynamic atmosphere.

「金融機関、規制当局、執行機関が連携して新たなテクノロジーを活用し、インテリジェンスと情報を共有すれば、エコシステム全体が利益を得る側に立ちます。金融犯罪と闘い、急速に変化する犯罪類型に大きな影響を及ぼすことを目指してしっかりとした目標を据える上では、国際協力を重点を置くことが最も重要です。」

Radish Singh, SEA金融犯罪 コンプライアンスリーダー兼AMLパートナー、  
デロイト・ファイナンシャル・アドバイザー、フォレンジック、デロイト

# コンプライアンスにおける 機械学習の可能性

銀行はこれまでに行ってきたのと同様に、マネー・ローンダリング防止に向けて何十億ドルもの投資を続けていきます。

しかしながら、こうした脅威の進化との闘いにおいて、従来の技術的アプローチはあまりうまくいきません。多数の「誤検出」（一部の組織では95%<sup>2</sup>が誤検出となっており、98%がSARまたはSTR提出不要のものだった）が生じ、多くのリソースがその処理に追われるという、うんざりするような事態となっています。重要ではないどうでもいいようなアラートを処理するために、限られたリソースが煩わしい手作業に使われていることは間違いありません。

その上、マネー・ローンダリング対策（AML）コンプライアンスの肥大化するコスト（米国だけでも250億ドル以上<sup>3</sup>）が大量の未処理のアラートと共にコンプライアンスチームに押し寄せ、チームが「本物」の高リスク事象・顧客に集中できなくなっている可能性があります。

言うまでもなく、AMLの取り組みの強化に向けて、より効率的で実効性が高いアプローチが求められています。究極的には、コンプライアンスチームは、懸案の解決などのより価値の高い仕事に専念すべきであり、銀行全体で検知された犯罪類型を反映するようにポリシーや手続を継続的に見直し、更新すべきです。

これに対して、銀行は技術革新を適用する機会を活用する必要があります。これには、ロボット工学、コグニティブオートメーション、機械学習（ML）、データアナリティクス、人工知能（AI）をAMLコンプライアンスの枠組みに適用することが含まれます。その結果、銀行・金融業界は、コンプライアンスの負担を軽減するために、AIや機械学習の利用機会を模索してきました。

事実、世界経済フォーラムとデロイトが2018年8月に発表した「[人工知能（AI）が起こす金融エコシステムのトランスフォーメーション](#)<sup>4</sup>」と題した報告書では、AIの継続的な発展が金融機関のフロントおよびバックオフィスの業務を根本的に変えることになるかと述べています。さらに、AIの拡大により、長年続いている規制の調整や、グローバル金融市場の現行の構造の大きな変革が求められるだろうとも記述しています。この変革は、銀行の将来に向けた体制整備の強化を実現するために、コンプライアンスチームが新たなテクノロジーに戦略的に投資するチャンスとなります。

テクノロジー企業と銀行は、高リスクの国・地域を評価する能力を高め、問題がある、または疑わしい資金の動きを識別し、重要な公的地位にある者（PEP）や制裁対象者・組織のスクリーニング（審査）を精緻化するために、AIソリューションやツールを積極的に設計しています。また、規制当局も、銀行はリスクの識別や低減を改善するためにこのような先進技術を利用できるし、するべきだと同意しています。

「金融機関とフィンテックがAIやデータアナリティクスの実験と活用を進め、サービスを向上させる中で、政府機関は自らの支援、政策、規制がそうした動向に対応できていることを確保し、こうした新たなテクノロジーへの支援を続けていく必要があります<sup>5</sup>。」

Dr David Hardoon、シンガポール金融庁、最高データ責任者

テクノロジーおよびアナリティクスの主要な進歩のいくつかは比較的最近のものなので、AIや機械学習には実際に何が伴うのか、この2つの違いは何なのかということになると、混乱が生じることが多いのです。明確化のために言えば、機械学習はAIのサブセットです。AIのサブセットには他にも、自然言語処理、ロボット工学、画像認識、音声認識、ディープラーニング（深層学習）、バーチャルエージェントなどがあります。





つい最近まで、銀行は従来型のルールベースのAML取引モニタリングやネームスクリーニング・システムに依存してきましたが、ルールの敷居値が原因で多くの誤検出が生じています（これについては次のセクションで説明します）。そのため機械学習は、コンプライアンス・イノベーション・プログラムの改善に向けた行程を歩き始める多くの銀行にとって、最初の立ち寄り先の役割を果たしてきました。

コンプライアンスにおけるイノベーションは、誤検出の低減、そして銀行によるAMLおよびテロ資金供与対策（CFT）リスクの監視・対処方法の実効性の向上という、二つの目的のために必要です。アラン・チューリング（Alan Turing）の有名な言葉のとおり、「私たちが望むのは、経験から学べる装置です」。チューリングの考え方は、高まる脅威やリスクに直面している銀行やAMLコンプライアンスにも当てはまります。

業界が機械学習を推進する中で、こうした進展は銀行に対して、イノベーションの波の中でAIエコシステムの戦略的構築を検討する機会をもたらしています。従来の取引モニタリングアプローチからの教訓が示しているのは、縦割り型の環境での業務運営には落とし穴があるということです。中でも危ないのは、業界全体で生じている不整合です。

AIエコシステムがあれば、**基準の共有が進み、基準の透明性が向上することになるでしょう**。このことは、**機械の採用と主流への統合を検討する際に専門知識、実効性、効率を高める上で、業界に好都合となるでしょう**。



AIには、人間の知能の特性である作業を実行できるコンピュータが関与しています。人間が表現できるものはすべて、AIの適用を通じて模倣することが可能です。

機械学習はAIのひとつの領域またはサブセットであり、あらかじめ定義されたコーディングがなくても、コンピュータが学習してデータや作業のパターンを理解できるようになるというアクション（動作）が含まれています。機械学習は特に銀行内の取引モニタリングプラットフォームに適しており、強い影響を与えることが見込まれます。

## マネー・ローンダリングとの闘いへの 機械学習の活用および適用

AMLコンプライアンスに対する規制当局の期待は、銀行に対して、規制環境において正しい側に確実に立つこと、そして疑わしい取引や行為のより批判的かつ効果的な学習と検知に向けて機械学習の活用を検討することを促すという、**予想せぬ結果をもたらしてきました。**

そのため銀行は、大量のデータ資産を分析し、その結果から「学習」するために計算能力の増大を活用することに、強い意欲を示しています。

コンプライアンスの領域には、銀行の中核的なマネー・ローンダリング・テロ資金供与リスクの検知・報告システム内のプロセスの実効性、効率、正確性の向上に機械学習が寄与できる真の機会があります。以下にその例を挙げます。



1. 疑わしい行為を検知および認識し、状況に応じてリスク格付するよう、機械学習のアルゴリズムに教え込むことができます。例えば機械学習アルゴリズムは、顧客のプロファイルや行為に基づいてリスクをもたらさない異常ではない取引であると決定された取引を除外するタイミングを識別しつつ、「より大きな」リスクを学習し、それに焦点を合わせることができます。

これを適用する最大の機会は、マネー・ローンダリングおよびテロ資金供与の取引モニタリングプロセスにあります。従来型のシステムが検知するのは非常に限定的な類型で、回避される場合もあります。さらに、疑わしい可能性がある取引を見逃さないよう、網をより広く打っておく傾向があるため、これらのモデルからの結果には、「リスクの兆候」よりも多くのノイズが含まれています。

「正常」な活動に近い疑わしい取引を捉えるルールの敷居値を緩めることにより、必然的にアラートの件数が増え、それを解決するためにコストがかかる手作業でのレビューが必要になります。しかし、エスカレーションが必要な疑わしい行為は、そのアラートの中のほんの一握りにすぎません。

2. 既存システムのアウトプットと組み合わせることで、取引が本当に疑わしい場合を示す行動特性やサインを識別するよう、機械学習モデルを訓練することができます。異常検出などの機械学習の手法は、これまでは検知されなかった取引パターン、データ異常、疑わしい個人・事業体間の関係の識別に使うことが可能です。

このような機械学習の手法は、もはや固定的なルールを必要とはせず、既知の、または流行のパターンや脅威に基づいているため、銀行の環境の中に犯罪者が隠れるのはこれまでよりも困難になります。

**3. 機械学習はネームスクリーニングにも適用できます。**ネームスクリーニングとは、顧客の名前と、既知の犯罪者およびブラックリストや制裁の対象となっている組織・個人をまとめたグローバルリストの、システムによる照合作業のことです。

多くの銀行が直面する課題は、「曖昧さ」と正確さのバランスを取ることです。言い換えると、現行のテキスト照合アルゴリズムは、姓と名の順、称号、敬称、略称、名前のバリエーション、よくあるスペルミスなど、データ収集で出てくる可能性のある微妙な差異を追跡するための有効なツールとは言えません。また、よくある名前から本人を正確に特定するのが困難な場合には、この作業は一段と複雑になります。現行のルールベースのアプローチは煩わしい手作業になるため、コンプライアンスのための作業量の増大や、監視やモニタリングにおける隙間の発生につながります。

**4. マッチング基準の改善や、ネームマッチングの確率予測のために機械学習を適用することは、大幅な効率向上につながる**とともに、隠れたつながりの識別（利用可能なデータからリンク解析を行う）や関係の識別により、有効性の向上を実現します。

人口統計、ネットワーク、行動データなどの事業体に関する背景情報を増やしてデータを充実させることが、スクリーニングプロセスの正確性を真に強化することになります。

このほかに勢いを増している分野としては、不正検知、自動報告、強化監視（音声、映像、テキスト、パターンベースの取引モニタリングを含む）などがあります。

どこに機械学習を適用するか決める際には、銀行のイノベーション戦略、主な優先事項、独自の金融犯罪コンプライアンスリスク、既存の業務上の課題、長期的な実行可能性の観点から、機会を理解することが重要です。

コンプライアンスへのスマートアプローチは、戦略的商業的にも価値があるでしょう。コンプライアンスチームによるエスカレーションや調査が可能なく知られたリスクがあることに加え、「本人確認（KYC）」プロセスなどの従来からのコンプライアンス重視の方法を最適化することは、銀行が有する顧客の事業ポートフォリオを充実させる新たな機会をもたらします。

長期的に見ると、銀行はより完全かつ安定的な顧客プロフィールを保有し、これを顧客満足の獲得とロイヤルティの構築に向けた継続的な顧客管理の強化のために活用することができるよう。この点に関して、機械学習モデルは、サービスの無用な中断をなくすことによってコンプライアンスを最新化しつつ、より深化されカスタマイズされた洞察の獲得により顧客体験の向上を目指すことが可能となります。

事業効率という点では、コンプライアンスに機械学習手法を使うことは、手作業によるプロセスの削減、さらにはコンプライアンスチームの重荷になりがちな重複作業の合理化という、計り知れない可能性を持っています。このような改善はコストを削減し、コンプライアンス活動の意義を高めることにもつながります。

成功に向けた最初のステップには、以下が含まれます。

- 導入済みの既存テクノロジーの成熟度評価またはモデル検証、および高度化機会の特定
- 主要なリスク、脅威、事業の複雑さの理解（銀行のコレス先、顧客、既知の取引リスクを含む）
- 銀行内のAIおよび機械学習を対象とする実効性のあるガバナンスの枠組み – AML/CFTの統制に明確に焦点を合わせ、データの質の問題、プロジェクト管理、ステークホルダーの期待の管理とエンゲージメントへの対処に向けて整備される
- AIおよび機械学習導入の戦略、枠組み、想定される結果
- AIプロセスを運用可能にし、文書化するアプローチ（特に本番環境への導入と、使用されるモデルとアルゴリズムについての深い理解に焦点を合わせる）
- 運用可能にするアプローチと導入の結果を監視・検証するための適切な体制の構築、規制目標の達成と適切なリスクへの対処
- テクノロジーのノウハウやインフラの提供者として選定されたベンダーに対する確実なデューデリジェンス

# 機械学習を 理解し、 採用する

機械学習を活用することで得られる可能性があり、有効性の向上も約束されています。しかし、この行程を歩き始める前に対処すべき検討事項があります。

この白書に提示されたUOBのケーススタディは、これらの検討事項の多くを詳述しています。

主な検討事項は以下のとおりです。



## モデルの結果に一貫性と再現性があることを確認する

AML/CFT取引モニタリングの場合、高リスクのプロセスを処理する機械学習モデルは、統制の枠組みの不可欠な一部となることから、以下の条件を備える必要があります。

- 特に規制上の観点から、アシュアランスを与え良質な監査証跡を維持する目的で、本番環境において銀行の結果を再現する能力があること
- モデルがデータセット内の行為とパターンを学習することにより、一貫性のある結果を生み出すよう設計され訓練されること

パラメータのランダムな初期設定、計算を異なる方法で行う様々なチップ構造、データの変更、統計ライブラリの変更などの変動要因により、一貫した方法で結果を再現するのは難しい場合が多いことが認められています。

この内在する課題に対処するために、銀行はモデルのパフォーマンスを評価・検証するための堅牢で継続的なプロセスを整備しなければなりません。これには、パフォーマンスを測定評価し、訓練プロセスを文書化できる管理の枠組み、そしてステップを複製しても同じ結果が確実に出る管理の枠組みが含まれます。枠組みは、リリース前に、本番環境に加えられた変更がパフォーマンスに及ぼす影響をテストすべきであり、特定の構成要素やパラメータがパフォーマンスに及ぼす影響を理解するためにアルゴリズムのユニットテストも実行すべきです。



## 柔軟性とカスタマイズ

機械学習採用における変更の多さとスピードという観点から、あらかじめ組み込まれたデータセットを使うことで簡単に実装できる「市販」モデルへの需要が高まってきました。その裏側にあるのは、異なるデータセットを使った場合の不正確さです。

市販モデルの訓練に使われるデータは各銀行の独自のデータではなく、基礎的なデータや取引、主要な顧客セグメントやプロフィール、その銀行が提供する商品・サービスからの学習を反映していません。機械学習モデルもまた、その他のリスクの微妙な違いを含むデータや、既存のトレンドまたは類型を含むデータ（高リスクのクロスボーダー取引など）、または単純に顧客の行為と全く一致していないデータでは訓練されていません。

ほとんどの場合、銀行は次第に拡張性があり、導入可能な機械学習モデルを求めようになっていきます。銀行のニーズに合わせてモデルのカスタマイズが必要になる可能性がありますし、インパクトを維持しつつ拡張可能なモデルが求められるでしょう。このような状況では、カスタマイズによる比較的高い初期費用に注目するよりも、長期的なメリットと拡張性を評価すべきです。

欠点はあるものの、市販の機械学習モデルを使うことも依然として可能です。ただし、銀行独自のデータセット、プロフィール、要件に従って調整される場合に限られるべきでしょう。

さらに、該当する場合にはモデルの機能強化を図るため、転移学習（あらかじめ訓練されたモデルを新たな関連データを使ってカスタマイズする能力）、ネームスクリーニングにおける画像認識（既存の市販機械学習の画像認識モデルを、顔認識機能を実行できるよう修正できる場合もある）、自然言語処理などの追加導入を検討することも可能でしょう。



## 機械学習モデルの持続可能性、拡張性、産業化

### －POCから本番運用へ

モデルを概念実証（POC）から本番環境へと移行させるプロセスは、持続可能性、拡張性、産業化、そして統制などの必要な検討事項がすべて組み込まれるレベルまで産業化される必要があります。

モデルは本番に対処できるように拡張可能でなければなりません。

- 予測のために送り込まれる新たなデータ量
- パラメータを調整し、モデルの再学習に役立てるため、ライブデータからのフィードバックを活用
- 本番環境の設計に影響を及ぼすビジネス要件
- 適切でレジリエントな技術およびパフォーマンスのフェイルオーバー

銀行内で機械学習を産業化するためには、モデルの設計、使用、メンテナンスの一貫性を確保する適切なガバナンスが必要です。複数の機械学習モデル（市販の機械学習モデルとカスタムメイドの機械学習モデルを組み合わせることも可能）を導入し、リソースの効果的な活用と銀行全体のリスク管理を実現するためには、銀行全体の戦略、枠組み、プラットフォームが極めて重要となります。

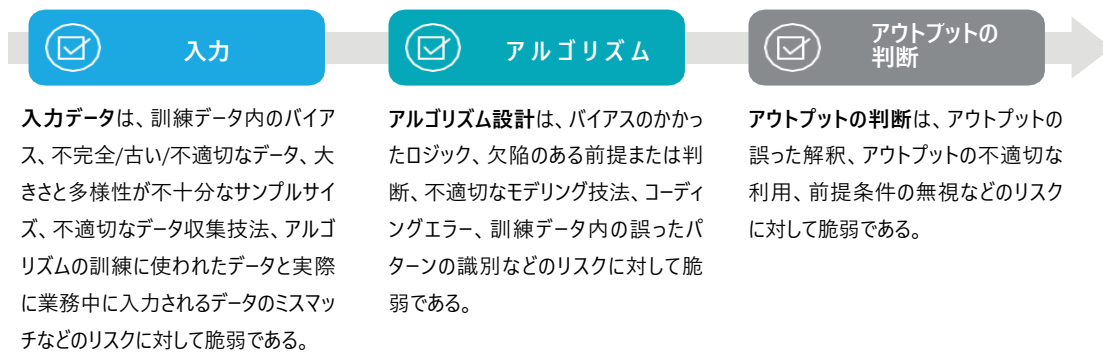
本番への移行には、正確性、完全性、プライバシー、規制コンプライアンスを実現するためのデータコントロールを組み込んだ集中管理プラットフォームの構築に向けた取り組みも必要となり、それが最終的には組織全体でデータの標準化と信頼性を確保することにつながります。機械学習モデルの成功のためには、クレンジングされたデータが直ちに必要です。この点については後続のセクションで詳しく見ていきます。





## 機械学習に関連するリスクの認識と対処

図1：機械学習モデルの使用に関連するリスク



### 基礎的要素

人間のバイアス	技術的な欠陥	使用上の不備	セキュリティ上の不備
人間のバイアス：モデル開発者またはユーザーの認知バイアスが欠陥のあるアウトプットにつながる可能性がある。また、ガバナンスの欠如や、組織の価値観と各従業員の行為の不一致が、予期せぬ結果を招く可能性がある。	技術的な欠陥：アルゴリズムの開発、訓練、テストまたは検証において技術的な厳密さや概念の健全性が欠如しているため、誤ったアウトプットにつながる可能性がある。	使用上の不備：アルゴリズムの実行、業務への統合、またはエンドユーザーによる使用に不備があると、不適切な意思決定につながる可能性がある。	セキュリティ上の不備：社内外の脅威アクター（攻撃者）が入力データ、アルゴリズム設計またはアウトプットにアクセスし、故意に欠陥のある結果が出るように不正操作する可能性がある。

出典：デロイト「Managing algorithmic risks: Safeguarding the use of complex algorithms and machine learning（アルゴリズムリスクの管理：複雑なアルゴリズムと機械学習の使用を保護する）」<sup>6</sup>

機械学習のような最先端テクノロジーのリスクを効果的に管理するために、銀行は確かな枠組みを構築し、従来のリスク管理の枠組みと能力を再編し、最新化する必要があります。これについては、「マネー・ローンダリングとの闘いへの機械学習の活用および適用」のセクションでも、主な成功要因について説明しました。



## 機械学習パイロットプログラムへの準備度

組織が異なれば、統合や活用への準備度も異なります。機械学習パイロットプログラムの前に以下の事項を検討すべきです。

図2：機械学習パイロットプログラムへの準備度

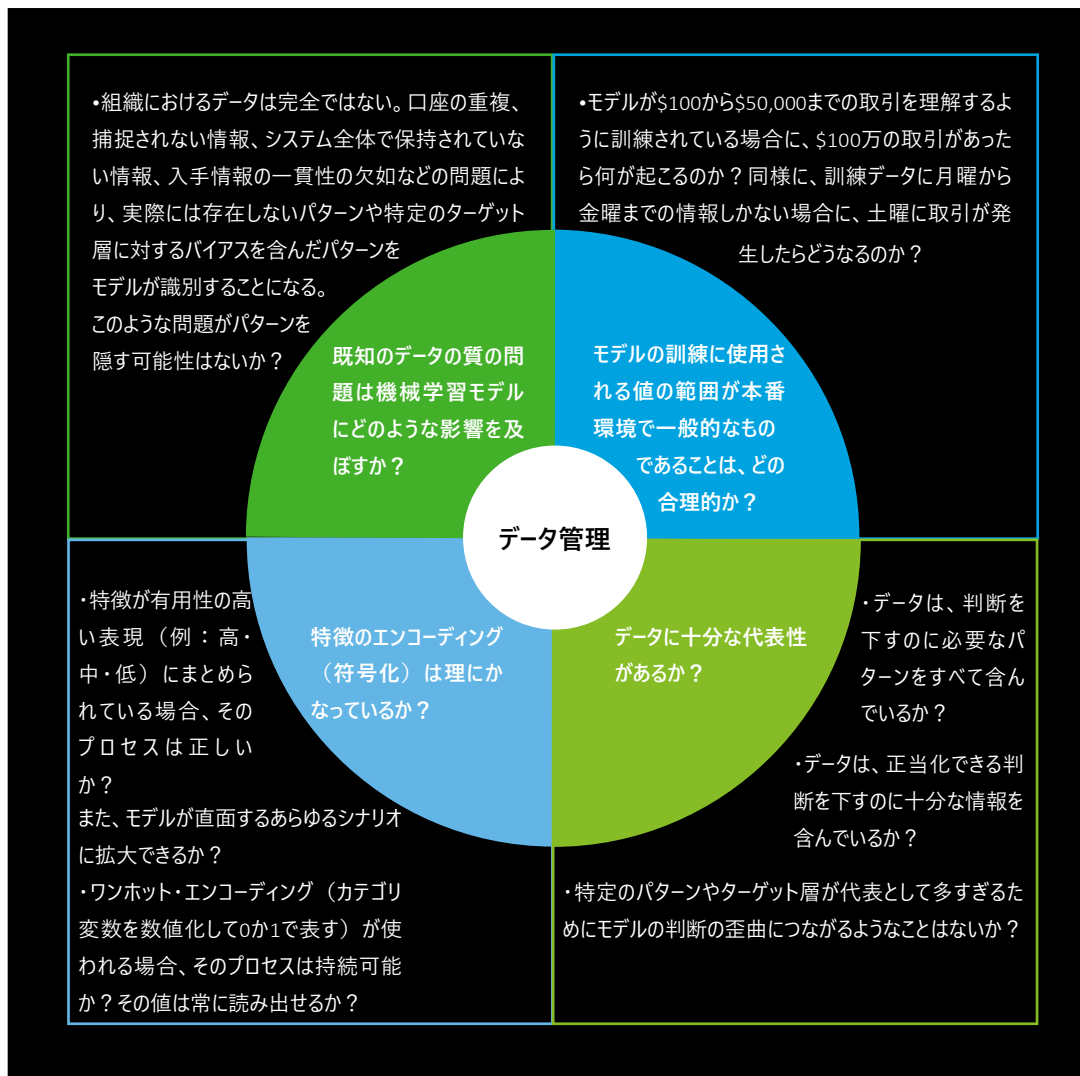





## データ管理

機械学習モデルの良し悪しは、モデルが受け取るデータの質にかかっています。データの質が不十分であれば不十分な結果しか得られないという簡単な結論が得られます。したがって、モデルを訓練するためのデータ選びが意図せぬバイアスを引き起こす可能性があります。このリスクを低減するためには、以下の事項を考慮することが重要です。

図3：データ管理のための検討事項





良質でクリーンなデータセットを持つことは、機械学習モデルの設計に挑戦するすべての銀行にとって、極めて重要な構成要素です。データ管理の基礎はデータの取得、準備、維持であり、機械学習モデルはそれに組み込まれています。それを受けて、管理の行き届いたデータインフラのメリットにより、複数の機械学習モデルがより豊富なデータセットを活用して貴重な洞察やパターンを提供できるようになり、特にマネー・ローンダリングおよびテロ資金供与と闘う際の複雑な分析に役立ちます。



## 機械学習モデル内部の 働きを説明する

パフォーマンスの成果を向上させるためにモデルがますます複雑化するにつれ、アルゴリズムの内部の働きはより不透明になっています。銀行は、アルゴリズムの復号と正確性の維持のバランスを取るという一筋縄ではいかない問題に、たびたび直面しています。

機械学習テクノロジーの採用と共に、銀行は機械学習モデルが使用するアルゴリズムを理解し、その正当性を説明できるようになることが期待されます。アルゴリズムは予測能力を向上させるかもしれませんが、著しく複雑化しています。モデルが妥当なパターンを拾い上げているか理解するため、また、訓練データを過学習していないことを確認するため、アウトプットは透明性があり、監査可能でなければなりません。

機械学習モデルがデータ内の関連性を拾い上げるとしても、それは必ずしも因果関係の証明ではなく、誤った仮説に終わる可能性もあります。誤った仮説が検知も是正もされないまま放置されれば、リスクの拡大やAML/CFTリスクの監視体制における正確さの欠如といった逆効果をもたらし、結果として正確な規制対応のアシュアランスが欠如している状態となります。

モデルを使う実務担当者は、コンピュータが下す判断を理解し、関連するデータポイントがどのようにして結果を形成するのかについて説明できるようになる必要があります。モデルの判断が公正で、倫理的で、法規制要件に沿ったものかどうかを判定するためには、判断に透明性があることが必要です



解釈可能性とは、人間が判断の原因を理解できる度合いを言います。これは、モデルの弱点を理解したり、規制当局やその他のステークホルダーに判断の正当性を説明できるようにしたりする上で、極めて重要です。

モデルが判断を下す理由を理解する方法のひとつは、モデルを動作させる重要な特性を正しく理解することです。これによりモデルの中核的な判断基準の決定が可能となりますが、特定の予測が立てられた理由を理解するには役立ちません。

さらに、予測が顧客に影響を及ぼす場合、顧客は自らのデータが使われる方法や、自らの銀行での体験に影響を及ぼすような判断が下された根拠について理解する権利を求めるかもしれません。

究極的には、AML/CFTの枠組みに導入されたテクノロジーは、それ自体の統制者でもあるのです。したがって、テクノロジーの説明可能性と透明性は、顧客体験の管理にとって、そしてリスクの適正な管理に関する継続的な規制対応のアシュアランスにとっても、極めて重要です。



この分野では、モデルが出す結果の説明可能性をいかに高めるかに関して、多くの調査研究が行われてきました。このような例として、SHAP（SHapley Additive exPlanation）とLIME（Local Interpretable Model-Agnostic Explanations）が挙げられます。これらは特定の特徴が局所的な予測に及ぼす影響を明らかにしようという試みです。SHAP はゲーム理論を使って、モデルの正確性と人間による解釈の間の隙間を埋めることで、両者の関連を明らかにしようとする手法です<sup>7</sup>。LIME は機械学習の分類の予測を支援するものです<sup>8</sup>。この分野での調査研究は現在も進行中です。



## 適切なベンダーパートナーを選ぶ

機械学習は、戦略、文化、技術環境、銀行が規制リスクに対処する方法、業務形態などに変化をもたらします。イノベーションが急速に進展する中で、大手金融機関がこのような課題に対処するためにテクノロジー企業と連携することが一般的になっています。

ベンダーリスクの管理は、ビジネスの持続可能性を維持する上で極めて重要です。テクノロジーベンダーの技術力のほか、適切な定評ある経験と財務上の持続可能性を有するパートナーを選定することも重要です。基本的に、成功するためには、適切な経験、専門知識、実績と共に、スマートテクノロジーが必要となります。

ベンダーをデータ環境に迎え入れる際には、銀行はデューデリジェンスを実施し、オンボーディング前の法務レビューと知的財産（IP）所有権が適切に管理・保護されていること、そしてベンダーの配置が安定的であるのみならず、法的に妥当で運用上実行可能であることを確保する必要があります。私たちの経験に基づいて言えば、新たなテクノロジーを導入する際には、ベンダーと銀行の双方が挙げる共通の障害がいくつかあります。

- データの取り扱いにおいて、規制要件に沿うこと、ならびに現地の管轄境界線を尊重すること（一般データ保護規則、非構造化データ、英語以外の言語等
- 技術ソリューションの持続可能性
- オンボーディング要件の明確なリスト
- オンボーディングの行程の一環としてのIPおよび共同作成したソリューションの所有権
- 双方にとって有益な期待に照らした成功の測定評価

## まとめ

AML/CFTにおいて、機械学習はまだ特効薬ではありません。

機械学習のあらゆる技法には強みと弱みがあります。それが何なのか、そして賢い適用はどのようなものかを理解することで、部分部分の合計を上回る何かを生み出せる可能性があります。有用な入手可能データには制約や増加する要件があります。アナリティクス、データエンリッチメント、統計分析、ロボット工学など、機械学習以外の他のアプローチも、この領域におけるいくつかの問題のより良いソリューションとして検討されるべきです。

問題を理解した上で、特定のユースケースやビジネスの状況に最適なソリューションを決定するために時間をかけるべきです。機械学習をビジネスプロセスに適用する場合でさえ、人間が必ず議論に入り最新情報を共有することは、これらのモデルのパフォーマンス向上のために常に有益です。判断をベースとする作業において、人間は機械よりも遙かに優れているからです。

人間は、新たなラベル付き訓練データをモデルに提供すること、誤った仮説を評価してそれを是正すること、規制当局、取締役会、経営陣から要求される必要なアシュアランスを提供すること、モデルのパフォーマンスを評価すること、予測されたアウトプットを使って複雑なケースに関する判断を下すことなどの追加作業を実行することができます。

機械学習を既存のプロセスに組み込み、インテリジェンスを用いてこれらのモデルを強化する方法のひとつは、モデルを各構成要素に分解し、構成要素ごとに「範囲を限った」モデルを作ることです。そうすることにより、特定のプロセスステップを強化できる集中的なモデルを作ることができます。次に、そこからのアウトプットを他のモデルに読み込ませてそのパフォーマンスを向上させたり、各部分に基づいて全体の判断を下すコントローラーに読み込ませたりすることができます。

こうした方法は有益である可能性がある一方、このレベルの複雑さを導入することに伴うリスクの増大もあります。例えば、システム内に広まるエラーの悪化です。モデルを確実に管理する枠組みを持ち、人間が監督するようにすることが、リスクの低減に大いに役立つでしょう。





## ケーススタディ

### UOB、Tookitakiおよびデロイトが、マネー・ローンダリングとの闘いを加速するための機械学習パイロットプログラムを準備

#### 企業の事業概要

ユナイテッド・オーバーシーズ銀行（UOB）は、アジア太平洋地域、欧州、北米の500カ所以上のオフィスと拠点から成るグローバルネットワークを有するアジア有数の銀行です。アジアではシンガポール本社、中国、インドネシア、マレーシア、タイ、ベトナムの銀行子会社、そして域内各国の支店や駐在員事務所を通じて事業を展開しています。

長年の市場リーダーであるUOBは、この地域の最も優秀な金融テクノロジーのスタートアップ企業やイノベーターの成長を促進し加速するアクセラレーターとなるフィンラボ（FinLab）を立ち上げました。フィンラボの支援により、シンガポールに拠点を置く規制テクノロジーのスタートアップ企業Tookitakiが、UOBと協力して共同開発した機械学習ソリュー

ションの提供の開始にこぎ着けました。このソリューションにより、UOBのコンプライアンスチームは、マネー・ローンダリング対策の一環として、より深く広範な分析を実施しています。

AML監視を強化するというコミットメントの下、UOBは機械学習の活用には大きな機会を見出し、不正資金の流れを発見し防止するための既存システムの拡張・強化に取り組んできました。

UOBは、目的に適合したAI駆動型のAMLテクノロジー、ツール、システムを単一の統合プラットフォーム上で開発するために、Tookitakiとの協力による共同開発を優先するという戦略的決定を下しました。

## マネー・ロンダリング防止スイート

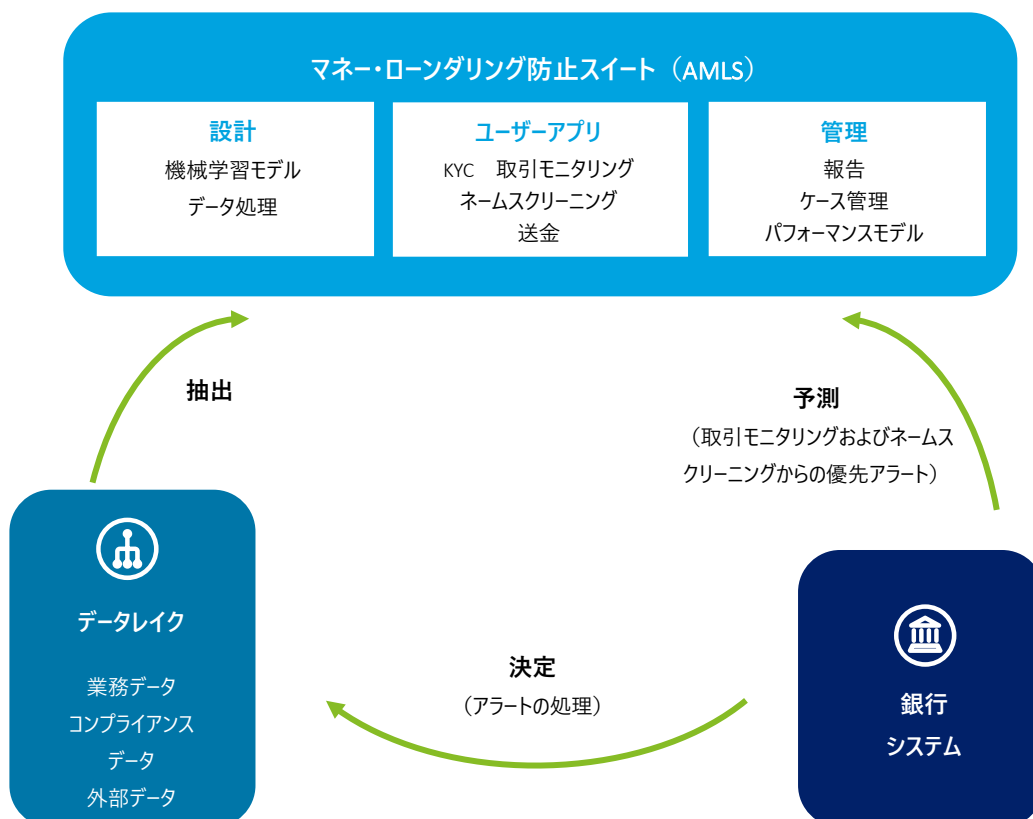
UOBは、モデルを概念実証から開発へと迅速に進めるために、本番環境を模した拡張可能な「サンドボックス」環境を作ることの重要性を認識していました。

利用可能な様々なオプションの戦略的レビューを経て、UOBは、同行のコンプライアンス要件に適したカスタマイズモデルの導入を決めました。カスタマイズモデルにより、UOBはコスト削減、効率向上、プロセスの簡素化などの具体的なニーズへの対応が可能となり、本番移行と稼働開始

の迅速化も期待できます。

「マネー・ロンダリング防止スイート」（AML）と名付けられたこの統合ソリューション<sup>9</sup>は、同行のAMLの枠組みにのっとして設計され、本人確認（KYC）、取引モニタリング、ネームスクリーニング、送金スクリーニングといった諸プロセスを特徴として備えています。UOBにとってAMLは、各種モジュール間での相互運用が可能なシームレスで簡潔なプラットフォームとして機能しています。


図4：モデルの迅速な開発と導入のための統合機械学習プラットフォーム



銀行内を流れる取引の規模と速度を考えると、UOBにとって、アラート管理、特に「誤検出」の削減とアラート終了の効率化をめぐる管理の最適化は極めて重要です。

AMLの重要な目標は、機械学習モデルと技法を活用した新たなソリューションとして、既存のルールベースの取引モニタリングシステムの上に新たな層として加わることです。その中心となるのは、高リスクな個人や企業の取引や活動、そして疑わしい活動からより良い洞察を獲得し、マネー・ロンダリングの可能性があるあらゆる活動に対して警戒を続けることに対する、UOBの熱心な取り組みです。したがって、AMLは新たな機械学習モデルと既存のルールベースのシステムのパフォーマンスを比較する手段でもあるのです。

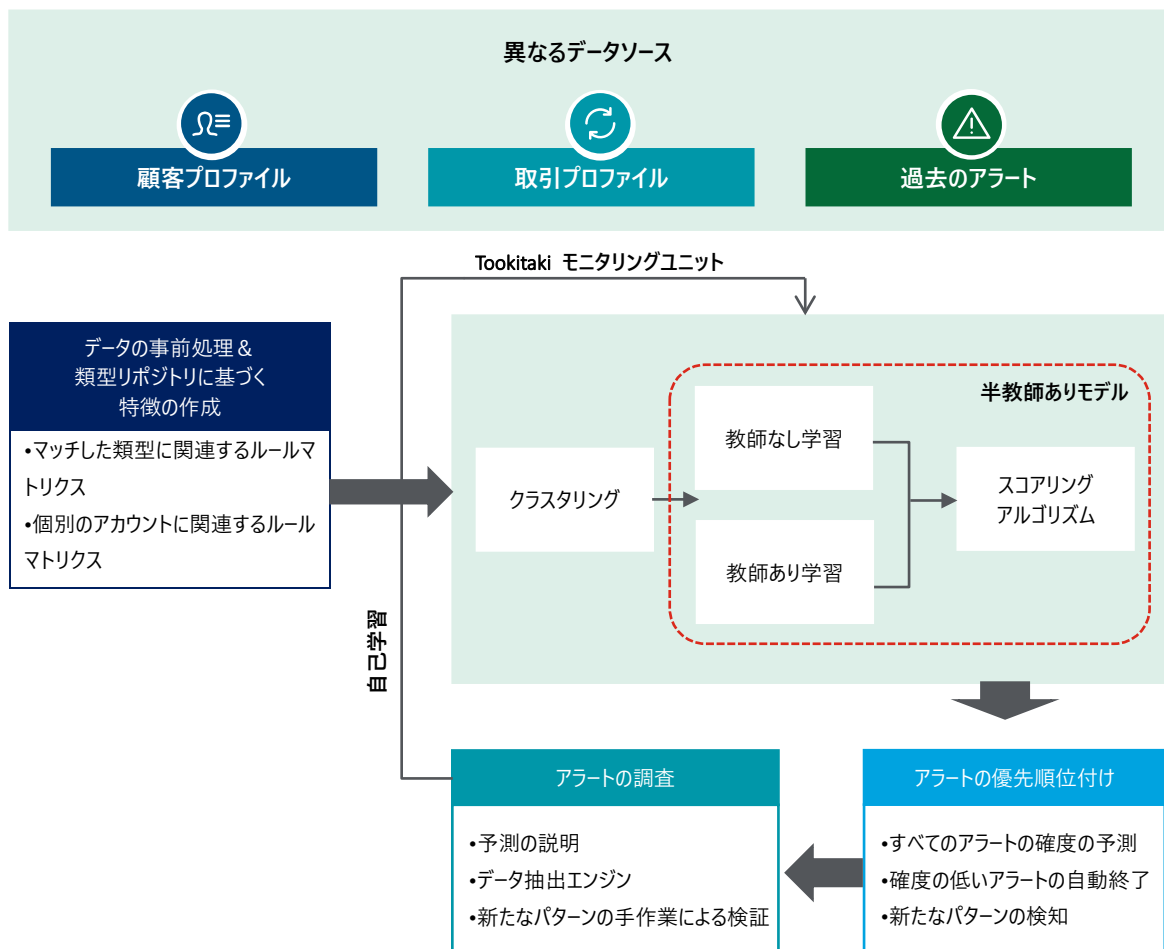
AMLを立ち上げるプロセスの一環として、UOBのコンプライアンスチームは、データ管理オフィスとTookitakiのフィンテック・データサイエンティストと緊密に連携し、AMLの枠組み内の4つの主要プロセスを対象とする別々のモジュールを評価、レビュー、導入しました。



## 機械学習、重要なアクセラレーター

取引モニタリングとネームスクリーニングを優先して、AMLSは機械学習モデルのパイロットプログラムを完了し、次の段階として残る2つのAMLプロセス、すなわち、顧客リスク評価および制裁のスクリーニングのテストを開始する予定です。取引モニタリングモジュールとネームスクリーニングモジュールの双方で誤検出を減らすことに加え、継続的に自動学習するための自己学習メカニズム、十分な理解のための「説明可能性」、質の高い調査力などの能力が、望ましいビジネス利益を実現するために非常に重要だと判断されました。

図5：アラートの優先順位付けへの機械学習の適用



「銀行・金融サービス業界では、複数のAIソリューションを取りまとめて、高度で統合されたAIの枠組みを構築する必要があります。TookitakiのAMLSは同じ指針に従い、拡張可能性と説明可能性を有しながら、既存の枠組みとのシームレスな統合を実現します。私たちのモットーは、複雑な問題を生じさせることなく金融機関が法規制を遵守するお手伝いをすること、さらには統合された持続可能なコンプライアンス管理を実現することです。」

Mr Abhishek Chatterjee, Tookitaki 創業者& CEO

とは言え、機械学習は単なる技術的側面を超えた領域に入っています。以下に、共同開発プロセスに関するUOBからの3つの教訓をまとめました。



1. モデルは大量のデータを必要としますが、そのデータは異なる場所に格納されていて、すぐに利用できない場合があります。しかし、機械学習モデルはデータに大きく依存します。データが良質であるほど、モデルの成功も大きくなります。開発プロセスを迅速に進めるためには、抽出プロセスを微調整するためのデータ情報の監査が不可欠となります。これにより、モデルをテスト、開発、導入するための安定的な環境が整備されます。



2. パイロットプログラムへの信頼を醸成し続けること。定期的な情報更新、指針、銀行内の様々な部署との緊密な協力関係が、プロジェクトを議論し精緻化するための場として、確かな情報に基づく強力な環境を構築するのに役立ちます。




3. さらに協力と共同開発を進めるためには、規制当局に早い段階で関与してもらうことも、新たな機械学習モデルの仕組みに関する透明性と説明責任の向上の促進に貢献します。


## 新たなレベルの効率と実効性を促進する

取引モニタリングモジュールに関して、UOBは、新たな未知の疑わしいパターンの検知を最適化すること、そして既知のアラートを優先することに重点を置きました。その結果、真に疑わしいアラートは5%増加、誤検出は40%減少し、大きな前進が示されました。

### 取引モニタリング




正しい判断の  
増加




誤検出の減少

ネームスクリーニングモジュールでも、同様の良好な結果が示されました。ネームスクリーニングプロセスを強化し、検知を改善するために、このモジュールは広範にわたる複雑な名前のバリエーションを処理できるように設計されました。また、このモジュールは、「推論」機能の拡充と追加の顧客プロフィール識別子の包含により、不確定のヒット数を減らすようにも設計されました。ネームスクリーニングのアラートについては、個人名の誤検出は60%、企業名の誤検出は50%、それぞれ減少しました。

### ネームスクリーニング



個人名の  
誤検出の減少




企業名の  
誤検出の減少

この結果は、AMLプロセスの中で誤検出を減らすために機械学習を使って何を達成できるかを示すとともに、機械学習への投資機会を増やすことでアラート管理の優先付けを着実に進めていけることを示唆しています。また、同様に重要なことは、ケース管理の能力およびスコアの信頼性を向上させることです。

機械学習パイロットプログラムへの投資により、業務効率は40%改善しました。マネー・ローンダリングのリスクに効果的に対処する実際の結果は、やり方を変えてみようとする洞察力の強化につながっています。

#### 業務効率




業務効率の向上

積極的な前進を受けて、UOBは、新たな取引データをデータベースに加えることにより、AMLの機械学習アルゴリズムの最適化を続けていきます。長期的な目標は、AMLの枠組み全体にソリューションを導入することです。同行はまた、機械学習を適用する際に、「ブラックボックス」とは対照的な「ガラスボックス（ガラスの箱）」アプローチを採用し続けることにより、機械学習モデルが下す判断を、分かりやすいビジネス用語で説明し言い換えられるようにしています。こうした取り組みは、エンドユーザーや規制当局との信頼関係を高めることにつながるでしょう。

モデルへの信頼感をさらに高めるために、UOBはデロイトに対して、パイロットプログラムとアプローチへの独立した評価の実施を依頼しました。

デロイトとの協力の下で初めての機械学習モデルの独立した継続評価を行うにあたり、UOBのAMLソリューションは、様々なAMLコンプライアンス類型に対処する能力があることを確認するために一連のストレステストを受けました。2018年8月に開始された評価における重要な優先事項は、デロイトがUOBのAMLモデルの概念の健全性を実証し、「目的適合性」を確認し、モデルのパフォーマンスを既存のルールベースの監視プロセスと比較することでした。





「UOBはリスク重視の強力な文化を守ることにコミットしています。この文化の中で、ステークホルダーの私たちに対する信頼を維持するための重要な柱のひとつが規制遵守です。AMLの領域では、防止、検知、執行の各措置を常に確実に把握するべく、絶え間ない警戒と継続的な強化が求められています。TookitakiのAMLSのようなレグテックの活用により、私たちはすぐに行動に移せるアラートを識別し、誤検出を最小限に抑える能力を高めることができます。それが私たちのAMLリスク管理の正確性と実効性を強化するのです。」

Victor Ngo、UOB グループコンプライアンス部門長

# POC から本番運用へ：

現時点で該当する場合には、「マネー・ローンダリングとの闘いへの機械学習の活用および適用」の章で説明した重要成功要因について検討すべきです。



## モデル導入の詳細な青写真から始める。

銀行は、モデルアーキテクチャがビジネスプロセス内で運用可能であること、そして必要な統制をすべて含んでいることを確保しなければなりません。モデルを段階的に運用し、パフォーマンスが期待に沿っていること、そして従業員が結果に自信を持てることを確保する必要があります。



## 適切な人材とリソースが、モデルの成果を十分に利用できるようにする必要があります。

この領域に機械学習を適用することのメリットは、エンドユーザーがプロセスを受け入れ、成果の活用方法を理解し、出された予測を信頼することで、初めて実現されます。その実現のカギとなるのは、レビューチームに研修を提供すること、そして特定の予測が出された理由をレビュー担当者に分かりやすく説明することです。



## モデルのライフサイクルにガバナンスを組み込む必要がある。

ソリューションの重要な側面が十分に理解され、文書化される必要があります。モデルと関連リスクを管理するために明確な役割と責任を定めるべきです。モデルが出す成果を継続的に監視し、役割と責任の範囲内での運用が維持されていることを確認すべきです。モデルに加えられた変更はすべて、監査のために保存し、復元できるようにしておく必要もあります。



## 機械学習モデルとアルゴリズムの文書化。

質の高い文書化の重要性を過小評価してはなりません。あらゆるモデルの検証の実施は、文書のレビューから始まります。文書は主要な要素をカバーしていなければなりません。その例として、テクノロジーとその機能性の説明、ビジネス要件、その成果、リスク低減アプローチ、テストおよびアシュアランス、障害復旧などが挙げられます。

## この先に何があるか？

AIの能力のメリットを引き出すためには、活用できる堅牢なエコシステムを持つ必要があります。導入と成長の成功に不可欠な関係者は社内外に複数存在します。

「AI管理の枠組み」の設計および開発に備えて、UOBは今後数年かけてAMLコンプライアンスのためのAIエコシステムの結束と強化を図っていきます。この取り組みの一環として、デロイトはUOBと協力し、AIを活用したAMLエコシステム管理の青写真を作っていきます。これには、堅牢なガバナンスプロセス設計の柱、ガバナンス運用モデル、AIソリューションの取得（テクノロジープロバイダーの選定からオンボーディングに至る全体への取り組み）、実行のメカニズムなどが含まれます。

社内では、テクノロジー、データおよびビジネス部門が協力して、まとまった戦略を策定し、企業の能力を活用すると共に、ユーザーのこの領域の専門知識を活用する必要があります。社外では、テクノロジーおよびハードウェアのプロバイダーが、ビジネスニーズを満たし、銀行に課された法規制要件に対応するソリューションを開発する必要があります。

したがって、規制当局はこの議論で積極的な役割を果たし、このようなテクノロジーの計画的な適用を支援すべきです。このようなテクノロジーの潜在的なメリットを十分に活用するためには、これらすべての関係者が協力し、重要な学びや成功要因、ならびに実効性があり持続可能なアプローチおよびモデルについて、互いに学び合う必要があります。

## 結論

結局のところ、これはツールやテクノロジーの話ではなく、実効性のある金融犯罪コンプライアンスの枠組みとそれに組み込まれたイノベーション戦略の話なのです。

結局のところ、これはツールやテクノロジーの話ではなく、実効性のある金融犯罪コンプライアンスの枠組みとそれに組み込まれたイノベーション戦略の話なのです。イノベーションは確かに、AML/CFTリスクのより良い監視方法を作り出すための良い「ビジネスケース」を提供してきました。

しかし、銀行はコンプライアンスのイノベーションに対して断片的あるいは対症的なアプローチを取る余裕はありません。リスクとコストが高すぎるからです。このため銀行はまず、自行のコンプライアンスの枠組み、独自の統制およびリスク環境、そして望ましい「顧客体験」を網羅した、明確なイノベーションおよびテクノロジーの強化戦略を検討し設計しなければなりません。

銀行にとってより重要なことは、複雑な活動パターンを識別し、「めったにない事象」を予測するための積極的な対策を講じることで、適切に策定された予防策と統制を確保し、疑わしい取引を検知・防止するため、あるいは進化する規制当局の要求に応えるために、事前対応的な措置を取る方向に進むことです。そのためには、ビジネス全体のポートフォリオ、取引および業務に対して統一された見解を持つことも求められます。

ビジネス、業務、コンプライアンス、テクノロジー部門をひとつのチームにまとめ上げることは、巧妙な組織的犯罪との闘いにおける新たな現実を受け入れるための戦略的対応です。

顧客、規制当局、株主、社会全体が、経営幹部レベルのリーダーと取締役会に対して、現在から将来にわたって組織を守るために実効性のある戦略を積極的に見つけ出すことを強く求めています。

AIに関して言えば、かつては単なる概念であり、議論される有望な可能性にすぎなかったものが、今や金融犯罪との闘いの転換点となっています。機械と人間と一緒に作業をするという新たな領域に向かって進んでいる銀行は、その分有利になります。これは、成功への道筋と基礎的要素を強固にするためには、すべての関係者が結集し、本当に必要なエコシステムを構築すべきだということも示唆しています。



「機械学習の活用に向けたUOBのパイロットプログラムの進展は、テクノロジー、新たなアプローチ、協力を含む包括的な企業戦略が金融犯罪およびそれに伴う複雑な問題への対応を加速するということを示す確固たる証拠となっています。多様なビジネスや取引があるASEAN地域は、革新的なソリューションの継続的な採用と金融テクノロジーから大きなメリットを受けるでしょう。」

Ho Kok Yong、デロイト SEA金融サービスリーダー



## 巻末注

1 Long Finance, China Development Institute, Financial Centre Futures, Z/Yen, The Global Financial Centres Index 24, September 2018, [https://www.longfinance.net/media/documents/GFCI\\_24\\_final\\_Report\\_7kGxEKS.pdf](https://www.longfinance.net/media/documents/GFCI_24_final_Report_7kGxEKS.pdf), accessed October 24, 2018.

2 Joshua Fruth, “Anti-money laundering controls failing to detect terrorists, cartels, and sanctioned states”, Reuters, March 2018, <https://www.reuters.com/article/bc-finreg-laundering-detecting/anti-money-laundering-controls-failing-to-detect-terrorists-cartels-and-sanctioned-states-idUSKCN1GP2NV>, accessed October 24, 2018.

3 Brian Monroe, “Financial Crime Wave – U.S. Compliance Costs surpass \$25 Billion, EU, U.K. AML Fines, and More”, Association of Certified Financial Crime Specialists, October 2018, <https://www.acfcs.org/news/422560/Financial-Crime-Wave--U.S.-compliance-costs-surpass-25-billion-EU-U.K.-AML-fines-and-more.htm>, accessed October 24, 2018.

4 Bob Contri, Rob Galaski, “How artificial intelligence is transforming the financial ecosystem”, Deloitte, August 2018, <https://www2.deloitte.com/global/en/pages/financial-services/articles/artificial-intelligence-transforming-financial-ecosystem-deloitte-fsi.html>, accessed October 24, 2018.

5 Monetary Authority of Singapore, “Strengthening the AI ecosystem in Singapore’s financial sector”, Media Release, 7 May 2018 <http://www.mas.gov.sg/News-and-Publications/Media-Releases/2018/Strengthening-the-AI-ecosystem-in-Singapore-financial-sector.aspx>

6 Dilip Krishna, Nancy Albinson, Yang Chu, “Managing algorithmic risks: Safeguarding the use of complex algorithms and machine learning”, Deloitte, 2017, <https://www2.deloitte.com/us/en/pages/risk/articles/algorithmic-machine-learning-risk-management.html>, accessed October 24, 2018.

7 Peter Cooman, “Demystifying Black-Box Models with SHAP Value Analysis”, Medium, May 2018, <https://medium.com/civis-analytics/demystifying-black-box-models-with-shap-value-analysis-3e20b536fc80>, accessed October 24, 2018.

8 Eric Brown, “Local Interpretable Model-agnostic Explanations – LIME in Python”, Python Data, January 2018, <https://pythondata.com/local-interpretable-model-agnostic-explanations-lime-python/>, accessed October 24, 2018.

9 UOB, “UOB and Tookitaki strengthen combat against money laundering through co-created machine learning solution”, News Release, 24 August 2018, <https://www.uobgroup.com/web-resources/uobgroup/pdf/newsroom/2018/UOB-and-Tookitaki-strengthen-combat-against-money-laundering.pdf>





# Deloitte.

## デロイト トーマツ

デロイト トーマツ グループは、日本におけるデロイト アジア パシフィック リミテッドおよびデロイトネットワークのメンバーであるデロイト トーマツ合同会社ならびにそのグループ法人（有限責任監査法人トーマツ、デロイト トーマツ コンサルティング合同会社、デロイト トーマツ ファイナンシャルアドバイザー合同会社、デロイト トーマツ 税理士法人、DT 弁護士法人およびデロイト トーマツ コーポレート ソリューション合同会社を含む）の総称です。デロイト トーマツ グループは、日本で最大級のプロフェッショナルグループのひとつであり、各法人がそれぞれの適用法令に従い、監査・保証業務、リスクアドバイザー、コンサルティング、ファイナンシャルアドバイザー、税務、法務等を提供しています。また、国内約 30 都市以上に 1 万 5 千名を超える専門家を擁し、多国籍企業や主要な日本企業をクライアントとしています。詳細はデロイト トーマツ グループ Web サイト（[www.deloitte.com/jp](http://www.deloitte.com/jp)）をご覧ください。

Deloitte（デロイト）とは、デロイト トウシュ トーマツ リミテッド（“DTTL”）、そのグローバルネットワーク組織を構成するメンバーファームおよびそれらの関係法人（総称して“デロイトネットワーク”）のひとつまたは複数指します。DTTL（または“Deloitte Global”）ならびに各メンバーファームおよび関係法人はそれぞれ法的に独立した別個の組織体であり、第三者に関して相互に義務を課しまたは拘束させることはありません。DTTL および DTTL の各メンバーファームならびに関係法人は、自らの作為および不作為についてのみ責任を負い、互いに他のファームまたは関係法人の作為および不作為について責任を負うものではありません。DTTL はクライアントへのサービス提供を行いません。詳細は [www.deloitte.com/jp/about](http://www.deloitte.com/jp/about) をご覧ください。

デロイト アジア パシフィック リミテッドは DTTL のメンバーファームであり、保証有限責任会社です。デロイト アジア パシフィック リミテッドのメンバーおよびそれらの関係法人は、それぞれ法的に独立した別個の組織体であり、アジア パシフィックにおける 100 を超える都市（オーストラリア、バンコク、北京、ハノイ、香港、ジャカルタ、クアラルンプール、マニラ、メルボルン、大阪、ソウル、上海、シンガポール、シドニー、台北、東京を含む）にてサービスを提供しています。

Deloitte（デロイト）は、監査・保証業務、コンサルティング、ファイナンシャルアドバイザー、リスクアドバイザー、税務、法務などに関連する最先端のサービスを、Fortune Global 500®の約 9 割の企業や多数のプライベート（非公開）企業を含むクライアントに提供しています。デロイトは、資本市場に対する社会的な信頼を高め、クライアントの変革と繁栄を促し、より豊かな経済、公正な社会、持続可能な世界の実現に向けて自ら率先して取り組むことを通じて、計測可能で継続性のある成果をもたらすプロフェッショナルの集団です。デロイトは、創設以来 175 年余りの歴史を有し、150 を超える国・地域にわたって活動を展開しています。“Making an impact that matters”をパーパス（存在理由）として標榜するデロイトの約 345,000 名のプロフェッショナルの活動の詳細については、（[www.deloitte.com](http://www.deloitte.com)）をご覧ください。

本資料は皆様への情報提供として一般的な情報を掲載するのみであり、デロイト トウシュ トーマツ リミテッド（“DTTL”）、そのグローバルネットワーク組織を構成するメンバーファームおよびそれらの関係法人（総称して“デロイトネットワーク”）が本資料をもって専門的な助言やサービスを提供するものではありません。皆様の財務または事業に影響を与えるような意思決定または行動をされる前に、適切な専門家にご相談ください。本資料における情報の正確性や完全性に関して、いかなる表明、保証または確約（明示・黙示を問いません）をするものではありません。また DTTL、そのメンバーファーム、関係法人、社員・職員または代理人のいずれも、本資料に依拠した人に関係して直接また間接に発生したいかなる損失および損害に対して責任を負いません。DTTL ならびに各メンバーファームおよびそれらの関係法人はそれぞれ法的に独立した別個の組織体です。

Member of

Deloitte Touche Tohmatsu Limited

© 2022. For information, contact Deloitte Tohmatsu Group.



IS 669126 / ISO 27001