

2019年4月15日
日本銀行
金融機構局
金融高度化センター

AI¹を活用した金融の高度化に関するワークショップ 第3回「信用評価」の様様

I. はじめに

日本銀行では、わが国の金融業界において、AIに対する関心の高まりや実際の取組みが急速に広がっていることを踏まえ、「AIを活用した金融の高度化に関するワークショップ」を展開している。第3回目は、2019年2月18日に、「信用評価」をテーマとして、以下のプログラムで開催した。

<第3回プログラム：テーマ「信用評価」>

▼開会挨拶

菅野 浩之（日本銀行 金融機構局 審議役 金融高度化センター長）

▼プレゼンテーション

「入出金情報を用いた信用リスク評価」

三浦 翔（日本銀行 金融機構局 金融高度化センター）

「AIを活用した信用評価の現状とこれから」

荒川 研一 氏（株式会社りそな銀行 リスク統括部 金融テクノロジーグループ グループリーダー）

▼自由討議

モデレーター

中山 靖司（日本銀行 金融機構局 金融高度化センター 企画役）

ミニプレゼンテーション「AIを活用した信用評価・レンディング」

菅野 浩之（日本銀行 金融機構局 審議役 金融高度化センター長）

— 参加者は、別添を参照。

¹ Artificial Intelligence. 人工知能。

今回のワークショップにおける議論のポイントは、以下のとおり。

- ① 財務情報以外の入出金情報等を使った信用評価（予兆管理）において、機械学習等の AI 手法が適用可能であるとの研究結果が報告された。機械学習を使った手法は従来のロジットモデルに比べ精度が高いことが確認できたが、ロジットモデルであっても相応の精度を確保しており、モデルの分り易さやコスト等を勘案すると十分選択肢になりうることも示された。
- ② AI を活用した信用評価の高度化（定性分析の AI 代替など）にあたっては、リスク（ブラックボックス化を含む）や限界を十分理解したうえで、人間と AI の適切な役割分担や目指すべき自動化のレベルを見極め、段階的に進めていくことが重要である。これは、対面／非対面チャネルの活用にかかる金融機関の戦略を踏まえて検討されるべきものである。
- ③ 融資領域における AI 活用は、省人的かつ迅速に業務処理できることから、不特定多数のマス向けを中心に強みが発揮される一方、域外から攻め込まれるなど一層激しい競争につながる恐れもある。地域金融機関にとっては、AI 活用による情報武装化や省力化で浮いたリソースの充当により渉外活動を強化したり、例えば同じ地域に基盤を持つ金融機関の間で協調してデータ連携を行う等、地域に密着した地域金融機関の強みを生かす経営戦略が考えられる。
- ④ 地域金融機関が AI を活用するにあたっては、完全内製化による自前対応から共同化、外部コモディティ製品・サービスの利用に至るまで、ベンダーの関与レベルに応じて様々な導入パターンが考えられる。パターンにより、必要な資源（ヒト、モノ、カネ）が異なるので、他行とどの領域で協調し、どこで差別化するのかといったビジョンを持ったうえで、費用対効果を勘案しつつ、身の丈に合った導入に向けた検討を行うことが大事である。

II. 開会挨拶（日本銀行 菅野 浩之）

本日の第3回会合のテーマは、「信用評価」である。信用評価への AI の活用は、具体的には、いわゆるオンラインレンディングを含む貸出審査の場面と貸出実行後のリスク管理の場面で行われるのではないかと思う。

例えば、第一に、担当者の属人的なスキルや経験に依存していた貸出審査の一部を AI が代替・補完することで、これを均質化するだけでなく、迅速化・効率化する。融資担当者の審査準備の負担も軽減できるかもしれない。また、これらの結果として、不特定多数に向けた貸出が可能となり、さらには、従来の審査基準で貸すことができなかった先の取り込みにつながる可能性も秘めている。

第二に、金融機関にとって、貸出先がデフォルトする恐れを少しでも早い段階で認識できれば、事前に対策を打つことも可能になる。そうしたデフォルトの予兆を的確に捉えるため、従前よりも多くのデータを用いて分析し、また、そのために AI を活用することが考えられる。

こうした整理を踏まえ、本日はお二人のプレゼンターをお招きしている。

ひとり目は、当センターの三浦である。三浦からは、現在、当センターがりそな銀行様、CRD 協会様と取り組み、この席にもおられる統計数理研究所の山下教授にご助言をいただいている共同研究について、概要を発表する。

入出金情報を用いた信用リスク評価をテーマとするこの研究は、銀行の勘定系データである口座の入出金データを基に、機械学習モデルを用いて、非上場の中堅・中小企業にも適用可能なデフォルトリスクの予兆指標を創出しようとする試みである。

やや学術的な内容になっているが、従来広く用いられてきたロジットモデルとの比較や分析時に苦労した点など、実務的なインプリケーションもできるだけ盛り込んでいる。

ふたり目は、りそな銀行リスク統括部金融テクノロジーグループの荒川グループリーダーである。荒川様は、金融商品のプライシング、リスク計測モデルや各種審査モデルの構築などの業務に長く取り組んでこられた立場から、データを活用した信用評価の高度化の流れや、現在活用されている事例などをご紹介いただくとともに、この分野で AI を活用していくうえでの課題などについて、包括的な整理をしていただく。

ラウンドテーブルの皆様におかれては、本日のワークショップが実り多く有意義なものになるよう、自由闊達なご議論をお願いしたい。

Ⅲ. プレゼンテーション要旨

1. 研究発表「入出金情報を用いた信用リスク評価」

(日本銀行 三浦 翔)

(1) ワークショップにおける本研究の位置付け

入出金情報を使った信用評価は、従来から審査等の現場では、RM(渉外担当)が経験則に基づき、与信先の信用力の変化を察知するなどの目的で、担当先の預金口座の残高や入出金の動きなどを目で見えて評価することが行われてきた。一方、入出金情報を与信ポートフォリオ管理に使おうとすると、情報量が非常に多いため、モデルあるいはシステム等によって対応する必要がある。足元では、金融機関におけるデータ整備やコンピュータ性能の向上等により、大量の情報・データを処理・分析できる環境が整いつつあるため、本研究では「入出金情報を用いた信用評価において、機械学習を中心としたAI手法が適用可能か」という分析を通じてAI活用の検証を行った。

(2) 本研究の問題意識

本研究は、中堅中小企業を対象とした信用評価に関し、①信用評価の予兆指標の創出、②財務以外の情報を使った信用リスク評価の実現、を目的としている。前者に関しては、大企業を中心とした上場企業には株価等の予兆指標が存在するが、中堅中小企業には使えるものがないこと、また、早期に信用力変化を捕捉しようと(頻繁にヒアリングするなどの)モニタリングコストをかけることは、与信額の小さな中堅中小企業には費用対効果が見合わない、との問題意識によるものである。一方、後者に関しては、中堅中小企業の財務情報は、会計知識が十分でない担当者によって作成される場合があるなど、信頼性に欠ける可能性があること、決算は1年あるいは四半期に一度などの頻度で更新され実態からタイムラグを含んでいる可能性があり、タイムリーな信用評価が困難であることが、問題意識となっている。

そこで、本研究では、①中堅中小企業でも算出可能な指標であること、②人の判断等の入らない情報をもとに作成される指標であること、③タイムリーに算出可能な指標であること、の要件を満たす予兆指標として、「預金口座の入出金データをもとにした信用評価指標」の創出を企図している。なお、入出金情報データは明細数が多く、抽出される情報量も多いため、より多くの指標を取

り込む必要があり、機械学習モデルを採用することとした。また、従来から信用リスク評価モデルとして広く用いられてきたロジットモデルと比べると、どの程度の差があるのか、精度比較を行った。

(3) 分析に用いたデータ・モデルの概要

今般の分析で使用したデータは、中堅中小企業の 2014 年 10 月～2018 年 5 月（計 44 ヶ月分）の入出金情報、及び、対応する格付（デフォルト²含む）である。上記データから、約 8,000 件（うちデフォルト約 1,400 件）を抽出し、モデル構築を行った。なお、モデル構築時に、トレーニングデータ（モデル学習用データ）とテストデータ（モデル検証用データ）に 2 分割し、パラメータのチューニングを実施している。

(a) 入出金データ概要

入出金データは、摘要コードをもとに、入金を 4 グループ、出金を 6 グループの計 10 の摘要グループに集約している。また、預金残高（月中平残）も用いており、合計 11 のグループの指標を用いている。

入出金情報は金額及び件数の項目にて月次単位で集計した指標を用いる。また、これらの指標をベースに、売上高などの規模を表す指標で各項目を割ることにより基準化を行った指標や、各指標の前月比・前年比、期間合計や標準偏差など、様々な指標加工によって指標のバリエーションを増やしている（合計約 6,000 指標）。これら加工後の指標を含め、摘要グループ（預金残高含む）の総称として、以下では「カテゴリ」と呼ぶことにする。

今般の分析は予兆管理を目的としているため、どの程度将来のデフォルトを予兆できるかという観点も重要である。そこで、デフォルトの観測期間は、入出金情報のエンド時点を基準時点とし、そこから 5 パターン（1・2・3・6・12 か月間）のデフォルト観測期間を設定し、各デフォルト観測期間におけるモデル精度を検証した。

(b) モデル概要

採用したモデルは、ランダムフォレスト・勾配ブースティングツリーといった機械学習モデル、及び、統計モデルである。

² 今回の分析では、デフォルトの定義として、債務者区分「要管理先」以下を用いた。

【ランダムフォレスト】・・・データサンプル及び指標をランダムに抽出し、多数の決定木を独立に生成する点が特徴。勾配ブースティング対比、過学習は発生しにくいモデル構造である。

【勾配ブースティングツリー (XGBoost)】・・・多数の決定木を生成する際、それまでに生成した決定木の結果から、モデルのフィットをより高めるように逐次的に決定木を生成する点が特徴。過学習が発生しやすいモデル構造で、パラメータのチューニングを丁寧に行う必要がある。

【ロジットモデル】・・・信用リスク評価モデルで最も広く採用されている統計モデルの一つ。指標のスコア化や指標選択などによるモデル精度向上が必要。上記 2 モデルのような機械学習モデルに比して、過学習が発生しにくいモデル構造である。

また、今般の分析では、モデルの精度評価として AR 値を用いる。デフォルト予測モデルを評価する際に AR 値を用いることは一般的であり、デフォルト・非デフォルトの信用スコアの序列がどの程度正しく序列づけできているかを評価する指標として解釈される。対象とする母集団によってモデルの AR 値の水準は異なるが、中小企業を対象とした場合は、0.6 程度あれば十分な水準とされ、ベンチマークとなっている。

(4) 分析結果

(a) AR 値を用いた単指標分析

指標の各カテゴリにおける上位 20 指標の AR 値 (平均) を算出したところ、最も AR 値が高いのは、預金残高の指標であり、出金返済・入金売上などの指標が続いた。一方、各デフォルト観測期間の AR 値の水準を比較すると、デフォルト観測期間が長いほど (より将来のデフォルトを予測しようとするほど) AR 値は低下する傾向にあり、直感と整合的な結果となった。

また、全 5,989 指標中、各デフォルト観測期間において最も AR 値が高い指標上位 5 指標はいずれも預金残高の指標であった。ただし、各デフォルト観測期間によって、上位に並ぶ指標バリエーションが異なる点は留意する必要がある³。

³ 「預金残高」のカテゴリに含まれても具体的な指標は異なることがあり、例えば、「直近 1 ヶ月の預金残高 (平残)」のこともあれば、「12 ヶ月間の預金残高平均」のこともある。

(b) モデル構築のプロセスと結果

各モデルのパラメータのチューニング結果等は以下のとおり。

ランダムフォレスト	<ul style="list-style-type: none">・パラメータとして、決定木の数と指標ユニバース（決定木を生成する際の、指標サンプリングで抽出する指標数）をチューニング。・デフォルト観測期間が3ヵ月間のテストデータにおけるAR値が最大となるのは、決定木の数350、指標ユニバース数150のときで、AR値は0.7070。・指標重要度の上位20指標中、カテゴリが預金残高であるのが17指標と多くを占め、残りは出金返済の3指標が含まれるのみと、重要度上位の指標カテゴリの顔ぶれは限定的。
勾配ブースティング	<ul style="list-style-type: none">・パラメータとして決定木の深さと学習率η（イータ）をチューニング。・デフォルト観測期間3ヶ月の場合、テストデータにおけるAR値が最大となるのは、決定木の深さが4、学習率ηが0.01のときで、AR値は0.7329。・指標重要度の上位20指標中、カテゴリが預金残高であるのは8指標。その他は、出金返済が10指標と最多で、以下、出金原価と与信残高が1指標ずつ含まれる結果。ランダムフォレスト対比で、AR値の上昇が確認されたが、より多くの指標の情報を適切に取り込むことにより、モデル精度向上が果たされていると考えられる。
ロジットモデル	<ul style="list-style-type: none">・単指標AR値の結果や機械学習モデルにおける指標重要度を参照し、指標採用候補を検討。様々な指標組合せを試行し、ステップワイズ法（指標減少法）で最適な組合せを探索。・デフォルト観測期間3ヶ月の場合、最終的に選択された指標は20であった。預金残高の指標が多いが、出金返済や与信残高、出金原価などのカテゴリ指標も含む。

(c) 各モデルの検証と分析結果

①運用シミュレーション検証

機械学習モデルを用いた結果、いずれのデフォルト観測期間においてもAR値が0.7以上と、予兆管理指標として十分に活用可能な水準であった。一方、ロジットモデルは、精度向上の余地があるものの、機械学習モデル対比で相応の差が確認された。ただし、ロジットモデルは、モデル精度が機械学習対比では劣るとはいえ、AR値0.65以上を確保しており、水準自体は実用に適さないほど低いわけではなかった。したがって、運用面（モデル理解のしやすさ、指標の感応

度などが分かりやすい) を勘案すると、機械学習ではなくロジットモデルを採用するという判断も考えられる。

②メイン・非メイン別検証

メイン取引先は入出金の流れをしっかりと把握できるのに対し、非メイン取引先では当該企業の入出金情報を十分には捕捉できたため、信用評価を適切に行うことができないという懸念があった。そこで、メイン取引先と非メイン取引先でモデル精度に差が生じているかを検証した⁴。その結果、メイン取引先は、非メイン対比でデフォルト予測精度が高いとの結果であった。もともと、その差は0.03~0.07とわずかであり、非メイン取引先においても相応の予測精度を確保している。RMが取引先に対する電話・訪問等を行わずとも予兆管理が可能となるため、非メイン先に対する予兆管理指標としても、費用対効果（モニタリング効率化）の観点から重要と考えられる。

③財務スコアリング計数の併用

内部格付を付与する場合など、法人債務者の信用評価を定量的に行う際、財務スコアリングモデルが広く使われている。そのため、財務スコアリングモデルから算出される計数（以下、財務スコア）を入出金情報の各指標と併用した場合、どの程度モデル精度が改善するかを検証した⁵。その結果、財務スコアをモデル指標に採用した場合、AR値が約0.1上昇し、0.8台後半の水準と極めて高い予測精度を実現した。入出金情報のみでも予測精度として十分な水準（AR値0.7強）であるが、財務情報を加えることにより、即時性と予測精度の両面を有する予兆管理指標となり得ることになる。なお、中堅中小企業の財務情報は年に一度の更新であることが多く、信用力の変動をよりタイムリーに把握するためには、やはり入出金情報を用いたモニタリングが有効と考えられる。

（5）おわりに

今回の共同研究における分析で苦労したり時間がかかったりした点は、AIを活用するプロジェクト全般に通じるものである可能性があるため、参考までに最後に紹介する。

⁴ 口座入出金情報から計算可能な、直近12ヶ月の「入金売上」合計が財務上の「売上高」に比して30%以上有する債務者をメイン取引先と定義した。

⁵ 財務スコアは、CRD協会の財務スコアリングモデルを用いて算出。

①データ整備編

入出金データは長期に亘って保存されているが、比較的容易に取得・利用できるのは足元のデータに限られており、実際に分析を行うためには過去のデータを抽出・加工する必要があった。特に、テキストで保存されている過去データを整備し、利用可能なデータベースに加工する作業や、入出金情報特有のデータの前処理に工数を要した。

②モデル構築編

機械学習モデルは、パラメータのチューニングに トライ&エラーが必要となるが、一回あたりの計算時間も相応に要するため、最も時間的コストを要した。特に、ブースティングは過学習しやすい傾向にあるため、チューニングを丹念に行う必要があり、試行錯誤の繰返しには相当な時間がかかった。一方、ロジットモデルは指標の加工や選択などに工数がかかり、機械学習とは異なる観点でそれぞれに時間を要したが、今般の分析では十分な時間的コストをかけたとは言いきれず、今後発展の余地があると考えられる。また、入出金情報は財務情報よりも高頻度で得られる情報であるため、財務スコアリングモデル構築では従来検討したことのないポイントを整理する必要があった（例：デフォルトフラグの立て方等）。

（6）研究発表に対する質問と回答

- ・ ①今後、検証時期を変えたモデルのバリデーションは行う予定はあるか。
②財務スコアを用いたときの運用シミュレーションにおける AR 値はいずれのモデルにおいても上昇しているが、ロジットモデルとランダムフォレスト、勾配ブースティングの差がほとんどなくなっている。これはどうしてなのか、分析のなかで分かったことがあれば教えていただきたい。

—— これに対し、日本銀行三浦からは、「①時期を変えたバリデーションの必要があると思っている。特に景気後退局面は今回の学習・検証用のデータに含まれておらず、利用可能なデータの制約との兼ね合いはあるが、そういった時期のモデルの振る舞いを確認したい。②これはモデル構造によるものと考えている。ツリー系のモデルは指標をある閾値で二分割するため、スコアリングの序列の情報をうまく取り込みづらいが、ロジットモデルはスコア全体をそのまま情報として反映できるため、財

務スコアを用いた場合の AR 値の上昇度が大きく、結果的にモデルによる差が小さくなったと思われる。」との説明があった。

- ・ 我々も入出金情報をもとにした分析を行っているが、預金残高がデフォルト予測に有効な指標として上位にノミネートされており、先ほどの説明と整合的である。ただし、上位 10 項目だけ用いた場合でも、全体 150 項目を用いたときとモデルの精度はほとんど変わらなかった。上位指標の寄与度が高く、特に特定期間における預金残高の最小値の説明力が高かった。

—— これに対し、日本銀行三浦からは、「ご指摘いただいたように、情報量としては、それほど多くの項目を使わなくてもモデル精度は高い水準が確保されると思う。例えば、今回は入出金情報を 24 ヶ月分使っているが、13 ヶ月分・6 ヶ月分など期間を短くしても精度が大きく下がるものではないことを手元のシミュレーションで確認している。」との説明があった。

- ・ 財務スコアを加えると非常に精度が高い結果となるのは、入出金が財務と異なる情報を有していることが理由と考えられ、非常に興味深い。①例えば、財務のスコアは高いが入出金のスコアは低い債務者などの特徴があれば教えて欲しい。また、②財務スコアを用いることによって指標重要度はどのように変化するか教えて欲しい。

—— これに対し、日本銀行三浦からは、「①個別の債務者の特徴までは見ていないのでわからないが、今後確認して参りたい。②指標重要度は財務スコアリングを入れることによって大きく変わった。ご指摘のとおり、財務スコアリングに含まれない情報を入出金情報で捕捉していると思う。このような情報の捕捉の仕方は、ランダムフォレストよりも勾配ブースティングの方が得意なので、勾配ブースティングの指標重要度の変化を確認すると、財務スコアリングを用いたことによる影響が明確に見えると思う。」との説明があった。

- ・ 当社でも入出金情報を用いた同様の分析を行っており、金融機関へのモデルの提供を行って 10 年以上が経っている。このような分析を通じて、口座情報はデフォルト予測に非常に有効であることを確認している。一方で、それが何を表しているかを考えることが最も大事だと思っている。預金残高の指標が有効だが、預金残高が多いから大丈夫ということを示してもあまり意

味がないので、預金残高の効果（ウェイト）を抑えて、数ヶ月前の入出金の変動を重要視するようにモデルの構造を工夫する等も実施している。このような工夫をすると、従来のロジットモデルとの差が小さくなるが、我々も継続的な課題を検討しつつ分析を進めていきたいと考えている。その際、業種でモデルを区分するよりも、大型の受注があるような先なのか、定期的な入金がある先なのかなど、入出金の時間軸方向の類型によってモデルを分けた方が精度が上がる傾向を確認している。

- 当行も入出金データを用いて企業の予兆管理に適用できないか検討を進めてきており、実務に適用する段階にあるが、2点お伺いしたい。①予兆のアラームという観点では中身がブラックボックス化しても役割は果たせると思うが、債務者の信用評価としての運用を考えると、説明責任が重要になる。今回の分析を進めるなかで説明責任は論点になったか教えて頂きたい。②予兆管理として用いるならば、モデルで当てにいくデフォルトの定義を「要管理」ではなく「要注意」まで引き上げた方が実務的には有益なこともあると考えるが、今般の分析でこのような分析を行ったか。

—— これに対し、日本銀行三浦と共同研究を行っているりそな銀行の荒川氏からは、「①内部格付に用いる場合には厳密な説明責任が求められるが、現状ではその条件は満たせておらず、内部格付モデルと同等の使い方は難しいと考えている。財務格付をサポートするような使い方が足元の使い方としては現実的ではないか。②ご指摘の通り、実務的には要注意基準で予兆を行いたいというニーズもあり、要注意基準でもモデルを構築したことがある。この場合、要管理基準対比でモデル精度が低下する傾向を確認している。」との説明があった。

- 入出金データというタイムリーに入手できるデータを予兆管理に使うというのは良いアイデアだと思う。上場している大企業には株価があるため、予兆管理に用いている場合があるが、その場合は、確率プロセスモデルを用いることが一般的である。今回の分析では、入出金情報の時系列としての情報を活かしてきれていないのではないかと考えている。預金残高が強く効いているため、本指標をもとに確率プロセスモデルを構築することは可能ではないか。入出金データを確率プロセスのモデルで表現するような信用リスク評価モデルの既存研究などあれば教えて欲しい。

—— これに対し、日本銀行三浦からは、「平均や標準偏差などの指標加工によって時系列としての入出金情報の特徴を取り込もうと工夫しているが、ご指摘の通り、確率プロセスとして表現しているものではない。そのため、ご指摘のようなモデルの発展余地はあると考える。なお、過去の当センターワークショップにて、武蔵野大学・山中准教授は、受注情報を用いた信用リスク評価モデルについて発表している。その際に用いたモデルは、確率プロセスの一つである構造型モデルである。入出金情報を確率プロセスに適用することについて、山中准教授ともコミュニケーションをとって検討してみたい。」との説明があった。

2. 「AI を活用した信用評価の現状とこれから」

(株式会社 リそな銀行 荒川 研一 氏)

(1) クレジットスコアリングとは？

最初に、信用評価モデル・手法に関するこれまでを振り返ったうえで、今後の取り組みについて説明したい。また、最後に、活用に関する課題についても触れていきたいと考えている。

データ等を用いた信用評価モデルというと、企業の財務データや個人の属性情報をもとに信用度合いを評価し、点数化するクレジットスコアリングモデルが従来から用いられており、主に「貸出審査」、及び「債務者の信用格付の付与」において活用されている。事業性資金でいえば、企業の財務データや代表者等の属性情報をモデルに投入すると、デフォルト確率、あるいは与信の可否が結果として示される。結果の回答が非常に早く、融資の申し込みがあったその日のうちに申込者に結果を伝えることが可能なことが特徴として挙げられる。スコアリングモデルの活用メリットは、人の目を介さないため恣意性を排除できる点と、職人的な能力を必要としない点、及び結論を出すまでの時間が短くて済む点である。

スコアリングモデルについての歴史を振り返ってみると、最も早くスコアリングモデルを与信判断に用いたのは、公表情報の範囲では、米国では1990年前半のウェルズファーゴ、日本では1998年の東京都民銀行ではないかと思われる。ところが、2000年代の中頃、ちょうどリーマン・ショックの少し前頃から、ス

コアリング貸出において想定以上の貸し倒れが発生し始め、リーマン・ショックの前後になると格付けの良い先からのデフォルトが多発する状況となつてしまい、スコアリング貸出は失敗であったという認識が共有されるに至った。

(2) 従前からの信用評価モデル

スコアリングモデルにおいて従来から用いられているアルゴリズムには、ロジットモデルと決定木の2つがあるが、行われていることの本質は、情報量を絞り込むことによる審査過程の単純化（モデル化）である。こうした単純化によって審査業務の効率化・客観化が可能となる。一方、近年活用が広がっている機械学習は、情報量を絞り込むのではなく、逆に大量のデータを用いて精度向上を図る点と、人が発見できない複雑な関係を表現しようとする点で、ロジットモデルや決定木と異なっている。

ここでは、ロジットモデルと決定木を使ったスコアリングモデルによる審査のイメージについて説明したい。まず、ロジットモデルを使った住宅ローンの審査例では、単純化が一つの大きなポイントとなっている（大半の金融機関では、審査項目数が10～20項目程度と大きく絞り込まれている）。具体的な審査のイメージであるが、「物件金額」「職業」「年収」等の項目毎に、審査対象顧客が該当するカテゴリに応じた点数が設定されている。審査の流れとしては、当該顧客がどのカテゴリに該当するのかを判断しながら、項目毎の点数を出し、合計点数によって融資の可否にかかる判断、あるいはデフォルト確率の算出を行う手順を踏む。これらの各項目の点数をレーダーチャートにすると、点数の低い項目と高い項目が一目瞭然となるため、審査結果、許諾の理由が分り易く、使いやすいことも特長である。決定木も、仕組みややり方は異なるものの、ロジットモデルと同じく分り易い構造となっている。職業や年齢など、申込書の内容をもとにフローチャートのようにYesかNoかで辿っていけば、最終的に審査結果として、OKかNGに辿りつく仕組みとなっており、ロジックモデル同様許諾の理由が分り易い。

なお、スコアリングモデルを使った融資審査の実用例をみると、実務では、全ての顧客に対してスコアリングモデルで審査が完結するわけではない。スコアの良し悪しが明確な顧客については自動承認や自動否決を行うが、スコアが中間の値をとるはっきりしない顧客については、スコアのみでは与信の可否が判断できないため、審査担当者が、経験（定性評価）を勘案して許諾を判断する目視審査を行っている。審査モデルの精度が向上すると、この目視審査の件

数が減るほか、目視審査であっても審査の補助として使えるため効率化に繋がる。

（３）信用評価手法高度化への取り組み

2000年代のスコアリング貸出が上手くいかなかった理由としては、主に４点あると理解している。①モデル自体が未だ発展途上で十分な精度が確保できなかったこと、②通常、法人顧客融資の際に行っているような定性分析を併せて行っていなかったこと、③顧客から提出させた決算書の内容が間違っていた、あるいは粉飾されていた可能性があったこと、④モデル構築に使用したデータがモデル適用時と母集団が異なっていたこと、である。特に、④は重要なポイントであり、金融機関が実際に融資を実行した顧客のデータだけを用いて、否決したデータを使用していないなかで、実際に借入の申し込みを受けて審査モデルを適用する場合にも、適切な判断を行えるかどうか慎重に見極めていく必要がある。

こうした2000年代のスコアリング貸出における問題点を踏まえ、最近、信用評価手法の高度化に向けて、4つの工夫が行われている。①非財務データの活用、②定性分析の補助、③不正の排除、④顧客利便性の向上、である。①非財務データの活用については、1つ目の日本銀行の三浦様がプレゼンテーションを行った共同研究が、非財務データとして「預金口座入出金データ」を活用した事例であり、一定の成果が認められている。また、④顧客利便性の向上については、過去の反省に基づくものではないものの、最近の様々な技術の進展を受けた、顧客利便性の向上を意識したものであり、オンラインレンディングに代表されるサービスが事例として挙げられる。夜間等でもスマホ・PCによる借入申込みができれば、顧客にとっては非常に便利ということもあって、金融機関以外の業種からの参入も含め、多数展開されてきている。オンラインレンディングは、財務情報だけでなく多種多様なデータを大量に使用し、機械学習等も用いて分析し、審査を行う点に特徴があり、粉飾のリスクを抑えることが可能となるため、③不正の排除にもつながる取組みにもなっている。こうした特徴点は、2000年代のスコアリング貸出の欠点を一部カバーするものであると理解することもできる。一方、②の定性分析補助については、これまでAI活用等はなかなか進んでこなかった。一般的に、企業の規模が大きくなればなるほど、定性分析の重要性が高まるため、金融機関では、会社実権者へのヒアリングや業界動向などの定性分析に時間をかけている。また、定性分析を行うためには、長年の経

験・ノウハウが必要となるため、審査をベテラン社員に担当させているケースが多い。こうした定性分析の全てを AI で代替することは、現状では相当難しいと思われるが、一部であれば AI で代替する事例が出てきている。

金融機関において、定性分析がどのような方法・プロセスで行われているかについて説明すると、まずは①企業をイメージし、疑問点・問題点を抽出する。具体的には、代表者や業種、年商などから企業のアウトラインを掴みつつ、成長性や商習慣などを踏まえて企業の属する業界についての理解を深め、当該企業の強み・弱み、主要取引先や技術力について確認したうえで、②現場・企業を見て、経営者等の話を聞いて確認を行い、③企業実態を把握するといったプロセスをとる。

例えば、自動車のブレーキの部品を作っている企業の分析を例にとってみると、自動車業界と言っただけでも、担当者の頭のなかには相当な量の情報が入っている。具体的には、完成車メーカーを頂点に下請・孫請けで構成される企業グループの構造、販売会社であればその系列会社、海外市場における日本車の立ち位置、アジア市場の成長性などを頭のなかに入れて分析を行う訳である。AI を活用した定性分析補助とは、こうした分析を AI にやらせるということであり、こうした取組みが難易度の高い取組みであることは、何となく想像できるのではないか。

このような AI を活用した定性分析補助をどのように実現していくかについては、自動車業界における自動運転との比較で考えると分かり易い。

レベル	融資の自動審査	(参考) 自動車の自動運転
0	全て人が審査	ドライバーが全てを操作
1	財務計数・審査に用いる指標をシステムで算出	システムがステアリング操作、加減速のどちらかをサポート
2	数値データを用いたモデルによる審査補助・一部自動審査	システムがステアリング操作、加減速のどちらもサポート
3	ビッグデータ、非構造データを用いたモデルによる審査補助・一部自動審査	特定の場所でシステムが全てを操作、緊急時はドライバーが操作
4	一部の特殊な顧客を除いたほぼすべての顧客に対し自動審査	特定の場所でシステムが全てを操作
5	全く人の判断は入らずにシステムで審査	場所の限定なくシステムが全てを操作

現在、注目が集まっている自動運転であるが、10年前の時点では、殆どの人は自動運転が実現するとは思っておらず、ドラえもんやSF映画において描かれる世界の話であると考えていた。実際には、まずはブレーキのアシスト等から始まり、高速道路等の一定の条件下での自動走行といった具合に、少しずつ段階を踏むプロセスで進めた結果、足もとでは完全な自動運転の実現も現実のものとなりつつある。

AIによる定性分析補助についても、一足飛びに完全な自動審査を目指すのではなく、自動運転同様、幾つかのレベルに分けて段階的に実現していくプロセスが現実的な方法ではないかと考えている。そのうえで、現在すでに自動化が一定程度実現している個人の消費性ローンや住宅ローンは、現状レベル2の段階にあるとの認識を前提に、それなりに高めの目標を設定し、一方で、大企業・中堅向けの貸出は、完全な自動化は難しいであろうとの理解のもと、目標を低めに設定すればよい。考え方としては、AIで代替可能な分析はAIで代替し、人間は人間にしかできないような難易度の高い分析に集中することにより精度向上及び効率化を図る、といったことになろう。

例えば、AIで代替可能な定性分析にはどのようなものがあるかという点、以下のような事例がある。

【主要取引先調査】・・・融資先の取引先毎に入出金を月次で収集し、信用度の変化を把握しようとするもの。

【交渉履歴文書からの景況感調査】・・・CRMシステム⁶に蓄積されている顧客を訪問した際の交渉記録等の文書データから、特定企業に関する情報や、先行きの景況感を占ううえでのヒントとなる情報などを含む、顧客の“生の声”を抜き出すもの。地域景況インデックスを算出しようとする地方銀行の取組みなどがある。

【企業間ネットワーク】・・・入出金情報を使って、企業間のつながりやサプライチェーンのなかでの企業の立ち位置などを明らかにするもの。周辺の企業で破綻等が発生した場合、取引先企業にどういった影響が及ぶかを予見すること等ができる。

⁶ Customer Relationship Management System. 顧客に関する属性情報や取引履歴情報を統合的に管理するシステム。

【リスク要因把握】・・・様々なニュースから因果関係を抽出し、企業に影響を与えるリスク要因を分析する一方、企業の決算短信等を分析し企業業績に影響を与える事象を特定することで、ニュースと企業への影響との因果関係を分析し、つなぎ合わせて有用な分析を行うもの。

【イベント検知】・・・ツイッターに代表される SNS に書き込まれる様々な情報（給料の未払い等、経営状態の悪化を示唆する情報など）を使って、企業の信用力変化の予測に使う試み。問題が表面化する前に経営状態の悪化を把握することが可能となり、予兆管理の高度化が図れる。

（4）AI 活用に関する課題

最後に、AI の導入にかかる課題についていくつか紹介する。

（a）AI の導入パターン

AI の導入パターンとしては、大きく 4 つに分けられると考えている。1 つ目は、自社のデータを用いて、自社が中心となって開発する内製化に近いものである。2 つ目は、ベンダーの知見を活用し、自社データでモデルを構築するパターンである。3 つ目が、ある程度完成されたベンダーが開発した AI を使い、自社のデータを学習させてパラメータをチューニングしていくパターンである。4 つ目は、SaaS 等で提供されるパッケージ化されたサービスを契約して利用するパターンである。ただし、このパターンは、導入自体は簡単であるが、同時に他社も同じことをやっているため、差別化にはつながりにくい。差別化を目指すのであれば、金融機関自らが開発に一定程度携わっていく必要がある。勿論、自社開発はハードルが高いが、その場合は共同実施やコンサルティングの活用などで対応可能である。いずれにせよ、それぞれのパターンにより、必要な資源（ヒト・モノ・カネ）が異なるので、プロジェクトに取り組む際には、当該プロジェクトがどのパターンに該当するのかを予め認識しておく必要がある。

（b）推進体制

通常、ベンダーに AI 導入を委託するケースが多いと思うが、ベンダーの話す専門的な言葉が理解できず、意思疎通が不十分な結果、当初イメージしていたものと異なるというトラブルが発生することがある。この点、社内にデータ分析等を行う専門の部署等が設置されていれば、知見のある社員を通じてベンダーとスムーズな意思疎通が行えるため、こうしたトラブルは回避可能である。

加えて、銀行業務の経験がある担当者がデータをチェックすることも大切なポイントであり、こうした点からも、銀行業務とデータサイエンスの双方に通じた人材で構成されるデータ分析部署の存在が重要である。

(c) 金融分野での活用の難しさ

「金融」は、社会科学の一つの分野であり、人間の行動によって結果が大きく左右される分野である。したがって、人間の行動が変化すれば、それまで問題なく行われていた予測が上手くいかなくなる惧れがある。AI といえども、基本的には過去のデータに基づいて仮説・推計を行うため、データの傾向が変われば、以前の AI は使用できなくなってしまう。また、法令の改正等、ルールの変化があると、過去の経験則が使えなくなってしまうことがある。たとえ精度に優れた AI を構築したとしても、使い続けるうえではこうした点に留意することが大事である。

(d) AI の運営に関する課題

AI の運営に関する課題の 1 点目は、ノウハウの蓄積である。AI の円滑な運営には、銀行業務に関する知識は無論のこと、データ処理に関する知識も必要となる。このため、こうした AI を用いた審査ノウハウを蓄積し伝承できる体制を構築すべきである。2 点目は、人材育成である。これまで金融機関が融資審査のプロを育ててきたように、モデルを理解し改良できるスキルのある人材を育成していく必要がある。3 点目は、ベンダーとの権利関係である。モデルの構築時にはベンダーに委託するケースも多いが、金融機関及びベンダーの双方のノウハウが活用されるため、成果物の権利関係に関しては注意が必要である。4 点目は、モデルのブラックボックス化の問題である。審査結果に関しては許諾の可否の理由を説明する必要があり、説明責任をどのように担保するかが重要である。

(e) データ活用に関する課題

データ活用に関する 1 つ目の課題は、データの整理である。金融機関のデータは分析できる状態にないことも多い。テキストファイルやオフラインのストレージ、紙媒体での保存も多く、分析可能なデータに整理する必要がある。当行では、10 年間にわたる入出金データ等のデータベース化を一昨年より進めてきたが、足もと漸く作業の目途が付いたところである。2 つ目の課題は、データの加工スキルの問題である。データ分析をベンダーに依頼する場合でも、情報

管理の観点からデータの抽出及び匿名加工情報への加工は社内で行う必要があり、こうしたことを行える人材の確保が必要である。3つ目の課題は、データの網羅性である。当初、データが揃っているという話であったとしても、確認してみると必要なデータ項目が取得できていなかったり、レコードデータが全件揃っているわけではなかったり、何年も過去に遡って取得できない等、不十分なケースが多い。

(f) 導入及び活用に関する課題

導入に際しては、PoC⁷が実施されるケースが多いが、このPoCのやり方を巡っても、幾つかの課題がみられる。成功率を高めるためには、着手する前に、必要なデータが揃っているか、あるいは構築に必要な技術がきちんと備わっているか等を見極めることが重要である。また、PoCの結果が好ましくない場合であっても、安易に諦めることなく、原因分析をよく行えば有用な成果が得られることもある。PoCに対する評価も課題となる。「こんなことをやりたい」、「やろう、やろう」、ということで着手するのだが、PoCを実施する前に評価軸を設定し、共有しておかないと、PoCが終了した際、更に改善等が必要なのか、そのための作業をさらに継続する必要があるのかが曖昧となり、実用化への意思決定を行いにくい。最後の課題は、導入後の有効活用である。PoCが終了し、導入にまで漕ぎ着けたものの、実際にはあまり利用されないというのは、割とよく聞かれる話である。ユーザ部署等には、構築したモデル等が便利なものであると分ってもらう必要があることから、強力な推進体制が必要であろう。

⁷ Proof of Concept. 試作開発の前段階における検証やデモンストレーションを指す。

IV. 自由討議要旨

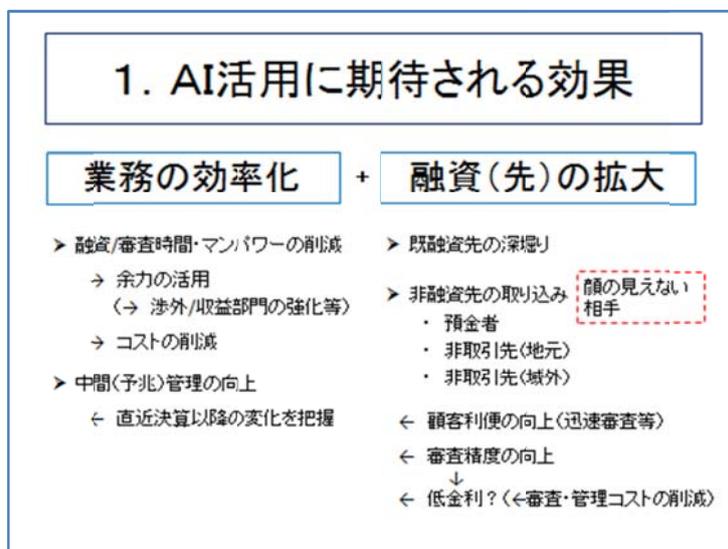
1. ミニプレゼン（日本銀行 菅野 浩之）

始めに、簡単な資料を用いて、特に地域金融機関を念頭においた問題提起をさせていただきます。

まず、最初に荒川様のご説明を踏まえ、私なりに信用評価・レンディングにおける AI 活用の特徴などをまとめてみた（右図）。ここでは、AI の活用とは、財務データに加え、入出金データや定性情報をもとに、機械学習モデルあるいはロジットモデルなどの

統計モデルを用いて、借り手の信用力を評価化し、その結果を踏まえて貸出を実行したり、中間管理を行うこと、をイメージしている。こうした AI の活用には、端的に言えば、貸出業務や審査業務が効率化すること、あるいは、融資先、融資量が拡大するといった効果が期待される。

これらの効果は、AI を活用すれば、多くの件数を省人的かつ迅速に業務処理することが可能になることに起因するものと言える（下図）。そうであれば、AI の強みが発揮されるのは、第一に、顔の見えない不特定多数向けの与信、第二に、小口・短期の与信またはそのリピートということになるかと思う。具体的には、小規模・零細事業者向けの貸付け、消費者ローン、住宅ローンなどである。



2. AI活用の強みが活きる領域

□ 多くの件数を、省人的かつ迅速に業務処理することが可能。

- ↓
- ① 不特定多数(顔の見えない相手)
 - ② 小口・短期(のりピーター)

(例)

- ⇒ 小規模・零細事業者向け貸付け
- ⇒ 消費者ローン
- ⇒ 住宅ローン

このような理解に立つと、大手行、営業基盤が大きな大手地銀、ネット專業銀行などは、全国あるいはマス向けに、AI を積極的に活用していく余地が大きいと考えられる（右下図）。

一方、こうした大手行などから攻勢を受けるかたちになる地域金融機関は、信用評価やレンディングにおける AI 活用にどのように取り組むべきと考えられるであろうか。

既存融資先への予兆管理のほか、地元の非融資先の取り込み、域外の非取引先

へのアプローチということが考えられるのは、大手行と同様である。ただ、地元の経済規模であるとか、域外での知名度といった点などを踏まえると、これらに取り組むうえで、コストに見合う効果を上げるには、どのような工夫が必要になるのかが大きな課題になると思う。

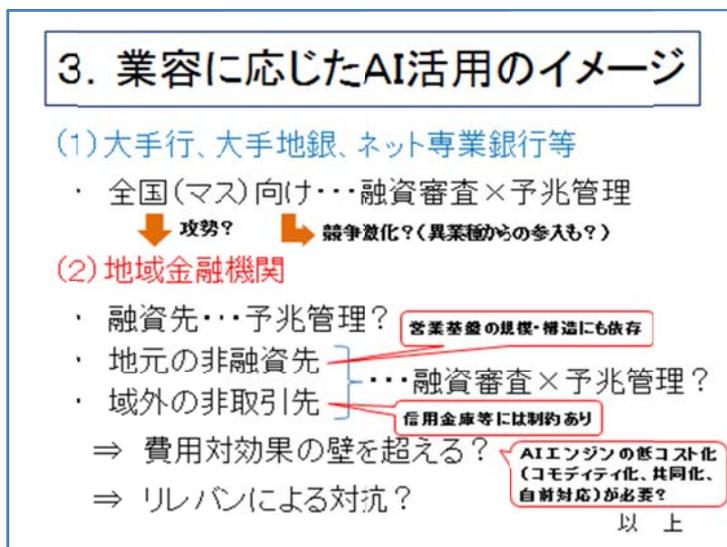
一つには、AI エンジンのコスト引き下げが重要なカギになる。ここでは、鶏と卵という面もあるが、コモディティ化による低価格化が求められるのかもしれない。あるいは、そのために、共同化や自前で対応するといった方策も考えられるが、そういったことは可能だろうか。

仮に、費用対効果に見合わないということだとすれば、それを逆手にとって、地域金融機関ならでの face to face の強みを活かした、これまで以上に強化されたリレバンで対抗するということが現実的な答えなのであろうか。

以上が、私からの問題提起である。

そのうえで、皆様にご議論いただきたい論点（例）は、信用評価・レンディングにおける AI 活用に関して、次の3点である。

- ・ 現状の評価、強み（メリット）と限界、注目される活用事例
- ・ 当面の課題とその克服の方向性
- ・ （中小の）地域金融機関における活用可能性



2. 自由討議

(1) 現状の評価、強み（メリット）と限界、注目される活用事例

(現状の評価－フロード⁸リスクへの対応の重要性)

- 2000年代にスコアリングを法人融資に積極的に活用しようと盛り上がった時期があるが、財務情報の粉飾や実体のない会社による申込み等が横行し、結局定着しなかった。今、個人融資の分野で、クレジットカードの不正利用が爆発的に増えているが、ネット上で貸出や与信が完結するが故に、逆にそうしたフロード対策が非常に重要視されてきている。スコアリングというクレジット部分に注目しがちであるが、フロードリスクをどう捉えるかも、この分野におけるオンラインでのビジネスの拡大のうえでは非常に重要ではないか。
- 同感である。現状、フロードリスク対策も色々と考えられているが、口座の入出金の流れを見るというのもその対策の一つだと思う。財務と入出金情報の両方を突き合わせれば、不整合チェックが行えるし、入出金情報を見れば、いわゆる回転売買等の不正な動きをつかむことができる可能性がある。過去の経験を教訓として、今まさに取り組んでいるということだと思う。
- これまでの議論のなかで、情報開示がクレジットリスクとフロードリスクにそれぞれ与える影響を分けて考える必要があると強く感じた。クレジットリスクは、モデル精度の問題であり、判断に至った事由を説明できる AI が求められるなかで、フロードリスクの観点からは、逆にモデルのロジック流出を如何に防ぐかが大事だと思っている。ブラックボックスだとロジックが分からないため安全であるが、ロジックが分かると当然その裏をかいて不正を行おうと狙われるので、公けにならないようにする必要がある。

(現状の評価－AI 導入の目的と効果)

- 私どもでは、昨年、住宅ローンの審査において AI の活用を開始した旨を公表しているが、目的は、信用リスク管理の高度化というよりも、どちらかという手順の簡素化、審査時間の短縮化である。現状では、審査時間が短いというメリットは十分追及できているとは思っているが、今後他行が追随してくれば競争が激化し、究極的には審査のための面会は不要というところまで行き着くことになるため、5～10年すれば当行の優位性もなくなると

⁸ Fraud. 詐欺などの不正取引。

思っている。結局、AIを皆がやれば、現在のATMのように、差別化は困難になると思っている。

- まだ実装には至っていない段階であるが、当行の取組みを、課題も含めてお話ししたい。2年前からAIの活用を探る観点から、技術ドリブンのトライアルを始めていたが、昨年になって実務展開を目指す業務所管プロジェクトに格上げしている。その目的は、これまで取引がなかった零細企業等の取込みと、効率化の両立であり、非対面チャンネルでのワンツーンによる肌理細かな提案を行うことを目指している。モデルは外部ベンダーと組んで構築しており、すでに一定水準のレベルまで達しているが、実務展開では別次元の難しさがあると感じている。
- 色々なデータを活用して、顧客が借りたいと思うタイミングでスマホ等によって案内する仕組みは、この後2~3年でどんどん世の中に出てくると思う。今まで中小の金融機関とも接点がなく見捨てられていた個人事業主等のニーズは、テクノロジーによって確実に拾えるようになり、新たな価値や需要を掘り起こすことにつながる可能性があるのではないか。
- 住宅ローンの審査にAIが必要なのかという議論があるが、AIによってモデルの精度が上がるからこそ、PD(デフォルト確率)値に信頼性が増して、案件の定量的評価につながり、透明性が増すのではないか。また、住宅ローンの場合、減額承認では顧客ニーズに答えられないが、AIの定量的な判断を支援材料に、少し金利を上乗せすることで満額承認する等の運用をすることも可能ではないかといった議論をしているところである。また、金融機関のなかで審査部門と営業部門の判断に差が生じることがあるが、定量的に評価できれば、共通認識に基づく会話ができ、認識の相違による機会損失の防止に役に立つと考えている。

(注目される活用事例—口座入出金情報を活用した融資審査モデル)

- 銀行が保有する口座入出金情報を使ってスコアリングモデルを構築し、短期の事業者向けの融資商品を一昨年からは始めている。取扱い一年半程で1,600件の申込みがあり、延べ実行額18億円、貸出金利7.9%の実績であった。なお、3ヶ月以上延滞は8件である。現在、恒常的に月々100件くらいの申込みがあるが、それ以上に大きな伸びはないという状況である。顧客の真のニーズに答えられていない可能性があるため、現在は短期資金のみであるが、資金の出し方を柔軟にしたり、もう少しモデルの精度を上げて現在の金

利設定（5%～12.5%）を引き下げる余地がないのか、さらに検討することが重要であると思っている。

（2）当面の課題とその克服の方向性

（当面の課題—AIを使うことのリスク管理）

- ・ 当行では、AIを住宅ローン審査の一部で使っているほか、口座入出金情報を使った審査など、様々な取組みがプロジェクトとして進んでいる。モデルの精度の良し悪しは当然として、国が3月末までに色々指針を出すという話もあって、「AIを使った際のリスク管理」が目下のところホットな議論になっている。例えば、モデル構築に使う学習データに関し、差別につながる可能性がある偏りをどうやって防いだらいいのか、加えて、ブラックボックスに関しても、それ自体はやむを得ないとして、どのように顧客に説明していくか、あるいはAIを利用していることを顧客にどう伝えていくか、ということが結構重要なのではないか、といった議論を始めている。政府の動向やGDPR⁹における「AIで判断されない権利」なども踏まえた議論も、今後必要になってくるのではないかと。

（当面の課題—AIで返済意思をどう確認するか）

- ・ 銀行が融資する時に返済能力のチェックは行われるが、本気で返済する気があるのかという「返済意思」の確認までは意外と行われていないと感じる。個人零細とか個人向けの融資ローンにおいては、この「返済意思」をAIを使ってどのようにモニタリングして確認するかも課題である。

（当面の課題—AIがわかる人材の育成）

- ・ 当行の状況では、りそな銀行のプレゼンの整理にある「データサイエンティストの確保による内製化」は、継続的なモデル改良等の運営負担を考えると、厳しいと思っている。したがって、実装は経験を踏んだベンダーに委託し、我々はその外部委託先をコントロールするとの役割で、マーケティング主体に体制を構築していこうと考えている。なお、その外部委託先をコントロールする立場であっても、AIに関する知見というのは一定程度必要となるため、その人材の育成が課題である。また、先ほど、組織横断的にデータ分析する部署が必要という話があったが、我々もその方向性を出していき

⁹ General Data Protection Regulation. 一般データ保護規則。EU域内の個人データ保護を規定する法として、1995年から現在に至るまで適用されている「EUデータ保護指令（Data Protection Directive 95）」に代わり、2016年4月に制定された（2018年5月25日施行）。

たいと思っている。

(当面の課題—AIで代替したヒューマンリソースの活用方法)

- 個人にとっても企業にとっても、金融行動のなかで一番顕在化しやすいニーズとして、「お金を借りる」ということがある。今でもAIがなくても十分ローコストで貸せるとの主張もあるが、そもそも、あえてAIを使ってまで今踏み出す合理的・経済的理由が本当にあるのか、という冷静な目も必要ではないか。結局、AIを信用評価の分野でどのように使っていくのかは、各銀行の戦略に依る。例えば、地域金融機関の場合、AIにどこを代替させて、高コストである人間というリソースをどこに使っていくか、ということからデザイン設計していくことが大切だと思う。

(当面の課題—融資における人間の介在のあり方)

- 今まで取引がない先にオンラインで融資をする会社がいくつも登場している状況にある。借入ニーズはあるが、銀行には来店しない既存顧客をマーケティングで惹きつけるのは理解できるが、素性が分からない新規顧客候補を探してきてオンラインで即日に融資するのは如何なものか。「この人に本当に貸すべきなのか」ということはしっかりと考えないといけない。いきなり口座を作ってローンを借りたいという顧客も多いが、その場合AIが判断で使用する入出金データは皆無であり、そういう先に貸したいのか、そこに貸すためのAIを作るのか、という点については、慎重な判断が必要ではないか。一足飛びに融資に向かうのではなく、現時点では、途上与信管理のなかでアラーム機能を発揮させることに活用することが、一番有効と感じている。そのうえで、AIに関係なく「本当に貸すべき人なのか」という判断の観点はしっかりと持っている必要がある。さらに、「ここまではAIに委ねる」、「ここはAIにはできないから、人がみる」というように、どう対応するかを探っていかなければならないと思う。オンラインによる融資を否定するつもりはないが、どのような場合に、人が介在しないまま、即座に自動的に融資してもいいのか、との議論が必要である。

(当面の課題—対面か非対面かは戦略次第)

- 一秒でも過去のことで、かつデジタル化されている分野はAIに代替され得る一方、一秒でも未来の分野に関しては人間が介在する余地があると思う。新規顧客は、個人／法人、対面／非対面にかかわらず過去の取引データがないので、AIによる融資判断の精度を上げることは難しい。その場合、保守

的に対面コストを払って管理するのか、それとも非対面と割り切り、不正取引等のリスクも含めてローコストで対応するのかは、戦略設計の差に過ぎず、メガバンクであろうと地域金融機関であろうと、業態の差は関係ない。先ほど議論になった「返済意思」や、「売上高拡大に向けた強い意思」のようなものは、おそらく非対面では確認することはできない。Face to face でコミュニケーションをとって定性情報で補うということであれば、渉外活動は残るし、そこは地域金融機関の強みかもしれない。一方、その点も含め、リスクは承知のうえで非対面によりローコストで運営するというのであれば、インターネットの活用など様々な方向性があるのではないか。

(当面の課題－顧客第一)

- 我々は、日本の経済を引っ張っている企業のために、資金提供できる方法はないかを考えている。インターネットバンキングを利用していなかった年配の経営者の方々でも、今やスマートフォンを自由に使いこなしている時代であり、今まで 10 年後と想像していた世界が、非常に速いスピードで現実になっていると感じている。非対面のオンラインレンディングも、3 年後には常識になる、くらいに考えていないと先を読み間違える可能性があるのではないか。そうしたなかでは、AI という手段を使うかどうかは別にして、どのように顧客に対して利便性を提供するか、銀行の役割である信用創造機能をどのように発揮して行けるのかについて徹底的に追及していかないと、逆に企業から選ばれない存在になってしまうのではないかと、非常に危惧している。

(当面の課題－モデルの普遍性)

- 十数年前の想定に比べると、この分野は若干後退しているのではないか。もっとデジタル化できたはずが、結局、ヒューマンタッチの重要性に立ち戻っていると認識している。また、2000 年代初頭のスコアリング融資の教訓を踏まえると、景気局面が大きく変化した場合に、以前に作ったモデルが引き続き有効なのかは一回検証してみないとわからない。法人融資に関しては、例えば、先ほどの預金残高に依拠したようなモデルが、業況が急激に変化した局面においても本当に有効なのかという点は、やはり、ある程度時間をかけないと結論が出ないのではないか。

(課題克服の方向性－データサイエンティストの育成)

- AI 技術者が不足していると言われていたが、実は、今必要とされている

のは、AI 技術者というよりも、データ構造化を行うデータサイエンティストである。したがって、当面の課題に対する克服の方向性としては、「データサイエンティストの育成」が一番だと考えている。もっとも、データサイエンティストは、実際にデータを触って経験を積み重ねないと育たないため、すぐに世の中に必要な人材を供給するのは難しい面がある。

(課題克服の方向性ーデータの共有)

- 米国では FICO スコアが個人融資の分野で一般に利用されているが、クレジットヒストリーがない等の理由により FICO スコアを有していない個人が一定割合いるのが実態である。そこで、昨年秋、FICO は、本人の承諾を得たうえで、API 連携により取引銀行、オンラインの買物履歴などの様々なデータを Credit Bureau に集めて、FICO を補完する別の新しいスコアを提供するサービスを始めている。これは当面の課題を克服するうえで参考になる。例えば、地元企業の取引データを、API 連携により、企業の承諾を得たうえで他の金融機関と共有する仕組みを作れば、分析の範囲が広がり、地域金融機関において面白い取組みが行えるのではないか。
- これから取引をしようとする新規顧客に関しては、既存の取引先と比べると、入出金を含めたトランザクションのデータの量に違いがあるため、そもそも AI には頼れない。しかしながら、他の金融機関が保有するデータを共有できる体制があれば、かなり有効に AI が活用できるようになるのではないかと議論している。
- データ共有は望ましいことなのかもしれないが、一方で、結果として顧客が他行に取られるリスクを懸念する向きもあるのではないか。また、別の論点として、ただでさえ、対面の世界では貸出競争が厳しいが、現在一定の利鞘が稼げているオンラインの非対面分野でも、今後、同様に競争が厳しくなっていく可能性はないのか。すなわち、AI エンジンの普及により構築コストが下がってくればなおさら、より低い金利でオンラインレンディングを行うことが可能になるし、さらに地域の枠を超えて外部から攻勢を受けるようになると、対面・非対面を問わず、競争が一段と激しくなる。結果として、オンラインレンディングは、一気にレッドオーシャン化していくのかもしれない。
- 過去にも、データの共有事例として、住宅ローン審査や、オペレーションリスクにかかわる損失事故のコンソーシアム化が行われたことがある。しか

しながら、地域におけるシェアが大きい金融機関にとっては、データ共有はメリットよりデメリットが大きいと捉えられることが多く、コンソーシアムに加わるインセンティブが小さいという問題がある。また、当社には創業したばかりの顧客を優遇したり相談に応じる支援サービスがあるが、「金利が何%だったらオンラインレンディングを利用したいか」というアンケートをとると、2%～3%と答える先が多い。これから様々な金融機関が参入してくれば、こうした金利水準にまで実際に下がっていく可能性があるということであり、貸出市場がレッドオーシャン化する可能性は、十分あり得ると思っ
ている。

(3) (中小の) 地域金融機関における活用可能性

(地域金融機関における活用可能性－法人の審査結果を個人に反映)

- ・ 信用リスクの高度化の観点では、融資の戦略上の判断に AI をどう使うかという論点がある。住宅ローンでは、結局、返済原資が勤務先の会社の状況に依ることになるが、私共は法人取引を行っていないため、他行比不利であり、限界がある。地域に密着した地域金融機関の強みを生かすことができれば、法人の高度な信用リスク管理を AI でしっかりやって、その法人に勤めている従業員、つまり個人の住宅ローン審査に反映させることができるのではないか。

(地域金融機関における活用可能性－地域金融機関対応モデルの提供)

- ・ 当社は、一つ目のプレゼンテーションにあった共同研究において、銀行の口座入出金データを、分析可能なかたちのデータベースに作り込む作業を担当した。口座入出金データを活用するにあたって一番難しかったのは、データ量が非常に多いとの点であった。その際の経験を踏まえると、地域金融機関が大量の口座入出金データを独力で使いこなすことは、かなり難しいと感じている。それでも、財務以外の情報を活用したモデルによって融資の可能性が広がるのであれば、地域金融機関と取引のある中小企業の金融円滑化につながる方法としては有望ではないか。そうした地域金融機関の状況を踏まえ、現在のモデルを地域金融機関でも活用できるように、バリエーションを広げていく可能性も考えていきたい。

(地域金融機関における活用可能性－AI による情報武装化で渉外活動を支援)

- ・ 最近の地域金融機関の経営戦略では、自動化によって浮いた大量の人材を渉外に回すことが大きなテーマとされている。過去 10～20 年の間に、若手

行員が融資渉外のスキルを失ったとされるなか、こうした行員の融資渉外活動を支援し、顧客のビジネスを深く理解するための情報武装化の手段として、AIは有効なツールである。今や、AIエンジニアや統計のプロも必要としない、安価で便利な質の高いツールが、海外のみならず国内でも提供されるようになってきている。顧客に関するデータを投入すれば、顧客に対しビジネスチャンスを進言したり、資金需要を予測したり、ソリューションビジネスのストラテジーを語ってくれるAIの実現には、それほどコストを要しないのではないかと。もっとも、マーケティングや業務を十分に理解していて、かつデータも扱える人はどうしても必要なもので、そこは頭取並みの給料を支払ってでも外部から採用するしかないかもしれない。

(地域金融機関における活用可能性－外部のAIサービスの利用)

- ・ 当社では、住宅ローン審査を効率化する観点からAIを利用している。すなわち、従来アルゴリズムや機械学習の組み合わせにより、月に数千件もの審査を実施しており、重要ツールとして十分活躍している。これに加え、先日、外部ベンダーと共同で、住宅ローンの審査業務をAIで行うサービスを発表した。「説明できるAI」との特徴を有するとされるが、精度の面でも、当社の既存のAIよりも優れていたため、今後当社でも利用していくことになる。また、ジョイントベンチャーを立ち上げて、他の地域金融機関でも審査業務にAIを簡単に活用できるよう、「サービス型」で提供していこうと実証実験を行っている。なお、本サービスでは、審査結果はPD値として出力するものであり、この結果をどのように判断し、謝絶あるいは条件付きで承認かは、地域金融機関がそれぞれの戦略に合わせ差別化できるようになっている。

以 上

ワークショップ参加者（敬称略）

（プレゼンター）

- 三浦 翔 日本銀行 金融機構局 金融高度化センター
- 荒川 研一 株式会社 りそな銀行 リスク統括部 金融テクノロジーグループ
グループリーダー

（招待参加者）

- 石原 和幸 株式会社 広島銀行 総合企画部 デジタルイノベーション室 室長
- 稲葉 大明 日本リスク・データ・バンク株式会社 代表取締役副社長
- 岩田 廉平 株式会社 三菱UFJ銀行 デジタル企画部 次長
- 河村 允誉 株式会社 三井住友銀行 企業調査部 信用企画グループ グループ
長
- 島田 直貴 株式会社 金融ビジネスアンドテクノロジー 代表
- 染谷 豊浩 有限責任監査法人 トーマツ デロイトアナリティクス ディレク
ター
- 高野 康 みずほ第一フィナンシャルテクノロジー株式会社 データアナリ
ティクス 技術開発部 部長
- 高橋 淳一 一般社団法人 CRD 協会 企画部 チーフアナリスト
- 西原 正浩 ソニーフィナンシャルホールディングス株式会社 事業企画部 マ
ネージャー
- 東 慶太 株式会社 ふくおかフィナンシャルグループ デジタル戦略部 サー
ビスイノベーション推進室 室長
- 豆塚 滋夫 株式会社 常陽銀行 地域協創部 主任調査役 兼 筑波大学 国際産
学連携本部 技術移転マネージャー
- 森本 昌雄 T&I イノベーションセンター株式会社 代表取締役会長
株式会社 千葉銀行 参与
- 山下 智志 大学共同利用機関法人 情報・システム研究機構 統計数理研究所
副所長 リスク解析戦略研究センター長 総合研究大学院大学 統計
科学専攻 教授
- 吉本 憲文 住信 SBI ネット銀行 株式会社 FinTech 事業企画部長

（日本銀行）

- 菅野 浩之 金融機構局 審議役 金融高度化センター長
- 山下 裕司 金融機構局 金融高度化センター 副センター長
- 中山 靖司 金融機構局 金融高度化センター 企画役

* 所属および役職はワークショップ開催当時のもの。