

機械学習による個人ローン審査業務のイノベーション

加藤 亮 | Kato Ryo

(株)金融エンジニアリング・グループ
コンサルティング本部
主任コンサルタント



■筑波大学ビジネス科学研究科博士前期課程修了（経営システム科学修士）。国内の特許調査会社勤務を経て、2009年に(株)金融エンジニアリング・グループ入社。以来、コンサルタントとして金融機関を中心にデータに基づく科学的な意思決定を支援している。2015年には機械学習の国際競技大会 KDDCup に同僚と共に参加して世界第2位を獲得した。

1. はじめに

我が国では個人ローン事業を重視する銀行が増えている [1]。個人ローンは住宅ローンと消費性ローンに大別される。近年、住宅ローンは熾烈な低金利競争に晒されており、収益性は低下の一途をたどっている。一方、カードローンに代表される消費性ローンの金利は最大18%程度であり、高収益が期待できる。このため、近年では個人ローンの中でも住宅ローンから消費性ローンに重点を移す銀行が増加している。

我が国における個人ローンの審査業務（以下、「業務」）では、顧客からローンの申し込みがあると審査担当者（以下、「審査官」）が審査基準と経験知に基づいて諾否を決定していたが、1990年代後半から省力化や合理化を図るべく機械学習が活用されるようになった。近年では、収益拡大に向けて機械学習を最大の武器として位置づける銀行も登場している。本稿では、邦銀の業務に適用されている機械学習と新たなイノベーションの潮流について論じる。

2. 機械学習を活用した審査のプロセス

ローン実行の可否を審査する際に、銀行は顧客に関する情報を基に多角的な視点から信用力を調査する。審査では機械学習により構築したモデルが活用されている。モデルとは現象を数理的な方法で単純化した表現であり、デフォルト^{注1)}の予測に用いられている（図1）。以下、業務における審査とモデル活用のプロセス（図2）について述べる。

図1 デフォルト予測モデルのイメージ

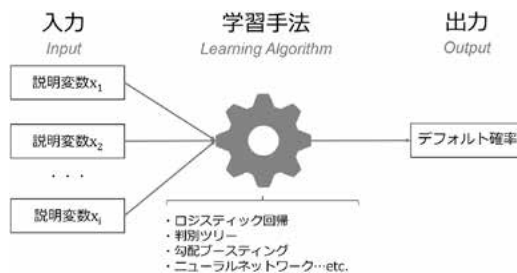
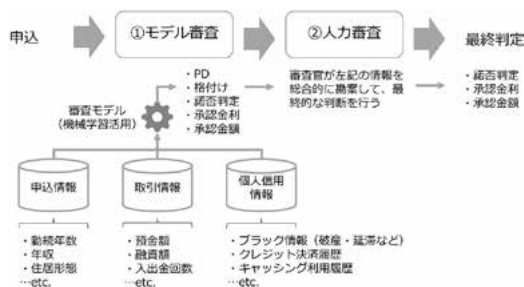


図2 審査プロセス



(1) モデル審査

顧客がローンの申し込みをする際に「年収」や「勤続年数」などの審査に必要な情報を記入した申込書を銀行に提出すると、先ずモデルによる審査が行われる。この際に参照される情報には申込情報に加えて、個人信用情報^{注2)}並びに口座を保有する顧客については取引情報などがある。モデルはこれらの情報を入力して信用力の尺度であるデフォルト確率 (PD: Probability of Default) とPDを所定の閾値で区分した格付けを同時に出力する。PDはコスト (信用コスト) として捉えられることから、この値を基に採算性の観点から許容可能な金利 (承認金利) と融資額 (承認金額) が算定される。PDが一定以上の場合には採算ラインを割り込むため、モデルによる審査結果は否認となる。

モデルの利点はデータに基づく合理的な判断が可能になることだが、逆に言えば、データに偽りがある場合や情報が電子化されていない場合にはモデルは機能しない。したがって、我が国ではモデルによる審査の完全自動化は一部の商品のみでしか実現されておらず、多くの銀行では人間によ

る審査が併存している。

(2) 人力審査

モデルによる審査が終わると次に人間による審査が行われる。審査官はPDが極端に低い或いは高い顧客についてはモデル審査の結論に従い、それ以外のPD帯の顧客については入念な審査を行う場合が多い。例えば、顧客の勤務先が実際に存在しているかを調べたり、申込書にある年収が疑われる場合には所得証明書の提出を求めたりする。勤務先や年収は顧客が任意に記載するものであり、稀に虚偽情報が紛れることがある。このような場合には人間固有の直感に基づく精査により、審査官がモデル審査の判定を覆すことがある。人間には機械が真似できない能力があるが、一方でその認知能力には限界があり [2]、判断にバイアスが生じることがある [3]。したがって、人間の判断の比重が大きすぎると偏った審査結果を招く恐れがある。つまり、審査の現場では人間と機械の協調が重要と言えるだろう。

上述のとおり、業務ではデータから導出されるPDや格付けといったモデルにより提供される材料を基に人間が最終的な意思決定を行っている。このプロセスを実現するには高精度なモデルの構築と適切な運用が前提となる。

3. モデルの構築と運用

業務で利益を向上させるためには、審査においてデフォルトしそうな顧客をなるべく否認しなければならない。そのためにはモデルの精度を高め

注1) 貸倒れや重度延滞 (90日以上の連続延滞) をデフォルトと定義する 경우가多い。

注2) 個人信用情報とは、顧客のクレジットカードやキャッシングの契約状況、借入・返済などの取引状況、さらにブラック情報と呼ばれる延滞情報や債務整理の情報等のことである。信用情報機関は加盟金融機関等からこれらの情報を収集している。

る必要がある。しかし、それだけでは不十分であり、モデルは適切に運用され続けなければ価値を生まない。これにはモデルに対する信頼が前提になる。一方、人間の判断にバイアスが発生している場合には人間の思い込みを適切に補正しなければならない。以下、モデルの構築と運用について具体的に述べる。

(1) モデルの構築

精度の高いモデルを構築するにあたっては、①データの収集、②説明変数の作成、③学習手法の選択の三つのポイントがある。以下、要点を述べる。

① データの収集

審査モデルを構築するためには十分な数のデフォルトデータ（通常は数百件以上）や実行情報を蓄積しておく必要がある。銀行内では、モデルの構築に必要なデータが一元管理されていることは稀であり、複数の部門に散在しているケースが多く、データの収集に時間がかかることが珍しくない。しかも、データベースではなく Excelなどで管理されているデータの場合は、複数列が統合されていることもあり、利用するために加工が必要になるなど地味に苦勞が多い工程である。

② 説明変数の作成

審査における説明変数はデフォルトする顧客としない顧客を上手く区別するための指標である。分析者はモデルを構築する際に顧客の計画性や経済力を説明変数として表現する。有効な説明変数を作るコツは顧客の行動をよく想像することである。例えば、デフォルトする顧客の典型例として、急に何らかの資金が必要になるといった場合があ

る。このような状況では、預金残高の急減などの現象がデータから観察される。これを「預金残高減少率」として定義すれば、デフォルトする顧客の特徴を表現できる。一方、審査官にヒアリングすることも有効である。デフォルトした顧客の特徴は審査官の知識として蓄積されており、審査官の知見や過去の体験から説明変数のヒントが得られることがある。このような工程を経て作成された説明変数は、現場の審査官にとって納得感が高いものになる。

③ 学習手法の選択

学習手法は複数あるため、データの性質や運用上望ましい手法を選択する必要がある。機械学習の技術の発展により、高い予測精度を実現する手法もある。しかし、このような手法は内部構造がブラックボックスである場合が多く、担当者の理解が得られにくいといった欠点がある。このため、我が国の審査モデルは一部の例外を除いて構造が明示されるホワイトボックス型モデルが採用されている。具体的な手法については次節にて述べる。

(2) モデルの運用

モデルは審査官に日々活用されているため、モデルの精度を定期的に確認（モニタリング）することはモデルへの信頼を担保する上で重要である。モニタリングにより、モデルの劣化が確認される場合やデフォルト率が想定よりも小さい状況が続くような場合には、各種パラメータの調整を行うことで改善を図る。

モニタリングではモデル精度の確認と同時に人力審査の傾向についても分析する。モデルによる諾否結果を審査官が採用しているかどうかを自動

注3) 自動化率 = モデル審査と人力審査の結果が一致する申込案件数 ÷ 全申込案件数

化率^{注3)}などの指標にて確認する。自動化率が低下傾向になると、モデル審査と人力審査との間に乖離が生じていることになる。このような場合には、審査官に状況の説明を求め、原因の究明に努める。モデルに課題が見つかる場合もあるが、一方で審査官の判断にバイアスが発生していることが判明する場合も珍しくはない。例えば、高額なローンのデフォルトが発生すると一時的に審査官が弱気な心理状態に陥ることがあり、これが原因でモデルが承認と出力していても審査官が否認する場面がある。

人間も機械も万能ではないので、モニタリングを通じて双方の擦り合わせを行うことが重要である。しかし、銀行によっては人間が全くモデルを信用していない場合もある。これはモデルの意義の周知や教育が不十分であることが原因であることもあり、分析者は分かり易い報告を心掛け、組織にモデルの意義を浸透させる努力を継続しなければならない。

邦銀ではモデルの構築と運用の両工程で銀行担当者と分析者が綿密に連携することで、その信頼性を維持・向上するよう取り組んでいる。しかし、実はこのようなモデルの透明性を担保する慣行が我が国のイノベーションを阻害している向きもある。この事象を考察するための準備として、以降では、モデルで適用されている機械学習の手法を概観する。

4. 業務に適用される機械学習の手法

業務に適用される機械学習の手法は複数ある。手法の選択はモデルの精度や可読性を決定する重要なポイントである。本節では、デフォルトの発生を予測するためのモデリング手法（教師あり学習 [4]）に着目する。教師あり学習は、モデルの構造を明示可能なホワイトボックス型と明示不能なブラックボックス型にタイプが分かれる（表1）。以下、各々について概説する。

表1 業務に適用される機械学習の手法

タイプ	ホワイトボックス		ブラックボックス	
学習手法	ロジスティック回帰	判別ツリー	勾配ブースティング(GBDT)	ニューラルネットワーク(NN)
イメージ				
概要	複数の「重み係数×変数」を合計。比較的単純な数式で表現することが可能	条件に「該当する」・「該当しない」で集合を分割を繰り返すモデル構造	多数の判別ツリーを組合わせた構造であり、最近ではこの手法を実装したXGBoostというパッケージが競技大会を中心に多用されている	複数のユニット（関数）で構成される層を重ね合わせた構造。近年では、深層学習と呼ばれる手法が注目を集めている
利点	・過学習しづらい ・予測対象の数が比較的少なくてもモデル構築が可能	・モデル構造が直感的で分かりやすい（実務担当者の経験則を取入れやすい）	・予測能力が高い ・変数加工が不要であり、比較的短時間でモデルを構築可能	・予測能力が高い ・深層学習では人間が説明変数を作らなくてもよい（自動抽出）
欠点	・外れ値の影響を受けやすいため、変数加工が必要となる場合が多い	・過学習しやすいため、モデル構築の際には比較的多くのサンプル必要	・モデル全体の可視化は困難（構成要素であるツリー単体の可視化は可能）	・モデルの可視化は困難 ・パラメータチューニングが難しい
業務適用	・国内外ともに事例数が多い	・国内外ともに事例数が多い	・国内では事例数が少ないが、米国では適用事例がある	・3層程度のNNの事例は多い ・深層学習の事例は数少ない

(1) ホワイトボックス型

ホワイトボックス型の代表例として①ロジスティック回帰と②判別ツリーがある。モデルが可読的であり、業務担当者の理解が得られやすいという利点がある。

① ロジスティック回帰

ロジスティック回帰は説明変数 x_i と重み係数 b_i を掛け合わせた数値を合算した Z 値をロジスティック関数に入力することで確率を出力する (図3)。ロジスティック回帰は数式が分かり易く、過学習が発生しづらいという利点がある。一方で、外れ値の影響を受けやすいため、精度を高めるには外れ値を丸めるなどの変数加工が必須となり、モデル構築に手間がかかるという欠点がある。

図3 ロジスティック回帰のイメージ

(1) ロジスティック関数

$$PD = \frac{1}{1 + \exp(-Z)}$$

(2) 線形回帰式

$$Z = \beta_0 + \sum_{i=1}^n \beta_i x_i \leftarrow \text{説明変数}$$

↓ ↓
定数 重み係数

② 判別ツリー

判別ツリーは説明変数を特定の条件で分岐させていき、最終的に性質が類似するいくつかの集合に分類する (図4)。モデルはロジスティック回帰よりも直感的で分かり易いという利点があるが、一方で過学習しやすいため、安定性の高いモデルを構築するためには比較的多くのサンプルが必要という欠点もある。

図4 判別ツリーのイメージ



(2) ブラックボックス型

ブラックボックス型の代表例として勾配ブースティングとニューラルネットワークを紹介する。これらの手法ではモデル構造の可読性は犠牲となるが、高い精度を実現できる。現状ではこれらの手法は国内の業務では浸透していないが、海外ではこのようなモデルが活用されている。

① 勾配ブースティング

勾配ブースティング (GBDT: Gradient Boosting Decision Tree) は判別ツリーを多段に組み合わせることで確率的な予測値を導出する手法であり、非常に高い精度を実現できる。業務で用いられる説明変数は多くても数十だが、GBDT では数万単位の説明変数を扱うことができる^{注4)}。さらに、面倒な変数加工が必要なく、比較的短時間でモデルを構築できるという利点がある。現状では国内の業務への適用事例は数少ないが、米国企業を中心に事例がある。

② ニューラルネットワーク

ニューラルネットワーク (NN: Neural Network) は生物の脳を模範にした手法である。複数のユニット (関数) で構成される層を重ね合わせた構造になっている。最近、圧倒的な高精度を実現できると話題のディープラーニング (深層学習) は層数が多いことが特徴^{注5)}であり、説明変数を自動で作成可能な点が革新的とされている。一方で、深層学習で高精度を実現するには非常に多くのパラメータを最適化する必要があり、特有の技術的な難しさがある。現状では、ローン審査や企業格付けのモデルに3層程度のモデルを適用した事例は国内外で数多くあるが、我が国ではあまり普及しなかった。深層学習についてはまだ適用事例が数少ない。

以上、業務で活用されている機械学習について

概説した。前節でも述べたように邦銀ではホワイトボックス型は活用されてきたが、ブラックボックス型の活用はあまり進んでいない。次節では、対照的にブラックボックス型を活用することで新たな地平を切り拓いた ZestFinance という米国の新興企業の事例を基に、我が国のイノベーションの可能性について論じる。

5. 個人ローン分野における機械学習の新潮流

ZestFinance は 2009 年に米国のロサンゼルスで創業した。創業者は Google の CIO を務めていた Douglas Merrill である。ZestFinance は最新の機械学習を適用することで、個人ローン分野でイノベーションを起こした。

米国では個人信用情報を基に算出される FICO スコア^{注6)} が顧客に付与されており、ローン審査の際にこのスコアが重視されている。しかし、FICO スコアが悪い顧客や、そもそもクレジットカードを保有していないなどの理由で FICO スコアがない顧客はローンを借りることが困難であった。一方、米国には信用力が低い顧客が利用する小口ローンがあり、金利は 40% 以上にも及ぶ場合もある [5]。このような状況下において、同社は最新の機械学習を活用し、高精度にデフォルトを予測することで金利を低減するとともに、従来はローンを借りられなかった顧客層を開拓することに成功した。その技術的な特徴として多様なデータとブラックボックス型モデルの活用が挙げられる。

(1) 多様なデータの活用

ZestFinance は顧客のローンの申し込み情報の他に、Web データ (アクセスログ等)、オープンデータ、地理情報及び SNS データなどの多様なデータを活用している。例えば、Web アクセスログからは顧客が初めてローンの Web サイトに訪問してから申込に至るまでの時間やローンに関する説明ページを何ページ参照したかといった情報を説明変数にしている。これらは顧客の「注意深さ」を示す指標であり、検討時間が長く、閲覧ページ数が多いほどデフォルトリスクは小さくなる。従来ではこのようなデータは活用されてこなかったが、同社は多様なデータを基に作成された 7 万もの説明変数をモデルの入力としている [6]。これほど膨大な説明変数を扱うためには、ブラックボックス型モデルの適用が求められる。

(2) ブラックボックス型モデルの活用

ZestFinance は膨大な数の説明変数を扱うために、前節で述べたようなブラックボックス型モデルを活用している。一般に、ブラックボックス型はホワイトボックス型よりも高い予測精度を実現できる。さらに、同社による特許出願 [7] では、ブラックボックス型であるランダムフォレスト^{注7)}、NN 及びホワイトボックス型であるロジスティック回帰のアンサンブルの事例が記述されている^{注8)}。アンサンブルとはこのように複数のモデルを組み合わせる技法であり、単一のモデルを適用するよりも高い予測精度を実現できる [8]。

注4) 筆者の所属組織では GBDT を用いて国際的な機械学習の競技大会 (KDDCup) で準優勝した経験が過去 2 回あるが、そのうち一方の 2015 年の大会 (KDDCup2015) では、GBDT により 3 万もの説明変数を入力にしたモデルを構築した。

注5) 2015 年の ILSVRC という著名な画像認識の国際大会の優勝チームは 152 層もの複雑なモデルを構築した。

注6) 米国のシステム企業である "Fair, Isaac and Company" が開発したモデルにより算出された個人の信用力の尺度。

注7) GBDT と類似する仕組みで複数の判別ツリーを組み合わせる手法。

注8) 国内の業務ではホワイトボックス型のアンサンブル事例はあるが、ブラックボックス型の事例は知られていない。

上述のとおり、ZestFinance は従来とは異なるデータと手法を用いてイノベーションを起こした。背景には FICO スコアと高金利がある。FICO スコアの弱点を突くべく従来とは異なるデータを用い、競合よりも低い金利を顧客に提示するために高精度のブラックボックス型モデルを活用したと推察される。そして、同社のモデルは個人信用情報が未発達な国でも有効という強みがあり、近年ではその代表例である中国に拠点を移すなどグローバルな活動を展開している。

一方、我が国では FICO スコアのような絶対的な基準は存在しない。そして、現状の消費性ローンの金利は高くても 18% 程度に過ぎず、いかにモデルの精度を高めても低減可能な金利の幅が小さい。さらに、人力審査の存在によりモデルの透明性が重視されていることも要因となり、ブラックボックス型モデルが必要となるようなイノベーションへの動機が働きづらいと推察される。このような要因が重なり、我が国の審査モデルは過去 10 年以上に渡って革新的な進歩はなかった。しかし、国内でも Web データを活用した審査モデルを構築する動きがある [9]。一方で、ZestFinance のような海外の新興企業が我が国に新規参入する動きもあり、このような環境の変化が新たなイノベーションの源泉になる可能性がある。

6. おわりに

最後に、これまでの議論を踏まえて、我が国の業務における審査モデルのイノベーションの方向性について筆者なりの見解を述べる。二つの方向性が考えられる。

第一に、多様なデータの活用が考えられる。近年はクローラー技術が進展しており、Web 上の様々なデータを収集して活用できるようになってきた。

一方で、異業種間のデータ連携の事例が発生してきている [9]。このように、従来は活用してこなかったデータに目を向けることで、新たな顧客層を開拓できる可能性がある。この点については、ZestFinance から学べることが多いのではないだろうか。

第二に、ブラックボックス型モデルの透明性を高める方向性がある [10]。GBDT のような手法は高精度かつ短期間でモデルの構築が可能という特徴があるので、審査モデルに活用するメリットは大きい。ブラックボックス型モデルは、人間で言えば暗黙知を有する専門家に近い。有能な専門家は分かり易い言葉で素人に理解を促す。ブラックボックスの中身を形式知として表現する技術が発展することで、機械への信頼性を高められるのではないだろうか。このような取り組みが我が国ならではのイノベーションに発展する余地は十分にあると考える。

*参考文献

- [1] 高橋昌裕 (2014) 『ザ・地銀』金融財政事情研究会。
- [2] Simon, Herbert A. (稲葉元吉訳) (1999) 『システムの科学 (第 3 版)』パーソナルメディア。
- [3] Kahneman, Daniel. (村井章子訳) (2012) 『ファスト & スロー』早川書房。
- [4] Hastie, Trevor. et al. (杉山将ほか訳) (2014) 『統計的学習の基礎』共立出版。
- [5] 坂野友昭 (2013) 「パーソナルファイナンスにおける金融イノベーション」(『早稲田商学』vol.438, p.39-67)。
- [6] 坂本達夫 (2013) 「新局面を迎えた消費者金融市場」(『JRI レビュー』Vol.7, No.8, p.107-127)。
- [7] Merrill, Douglas C. et al. "System and method for building and validating a credit scoring function" US2015/0019405. 2015-01-15.
- [8] 原田慧ほか (2015) 「データサイエンティストの思考法」インプレス (<http://it.impressbm.co.jp/category/c320040> [accessed on 2016-09-17])。
- [9] 「『金融-Fintech』の分野でオーディエンスデータ活用の新たな取り組み」DAC AD TECH BLOG, 2016-08-17 (<http://adtech.dac.co.jp/blog/2016/08/fintech/> [accessed on 2016-09-17])。
- [10] Hara, Satoshi et al. (2016) "Making Tree Ensembles Interpretable" arXiv preprint arXiv:1606.05390.
- [11] Nonaka, Ikujiro. et al. (梅本勝博訳) (1996) 『知識創造企業』東洋経済新報社。