

教育ローン向け審査モデルの高度化

(株) 日本政策金融公庫 国民生活事業本部¹
(株) 日本政策金融公庫 国民生活事業本部
05000227 専修大学 商学部
01505910 慶應義塾大学 理工学部

*戸城 正浩 TOSHIRO Masahiro
引寺 佑輔 HIKIDERA Yusuke
尾木 研三 OGI Kenzo
枇々木 規雄 HIBIKI Norio

1. はじめに

教育ローンは、融資金額が小口のため、採算を取りにくい商品である。金融機関では、融資申込先のスクリーニングに信用スコアリングモデルを活用することで、審査コストの低減を図っている。具体的には、図1のように、モデルから算出される信用スコアに閾値を設定して、信用スコアが閾値を上回る申込先は審査を簡略化（以下、簡略審査）する一方、閾値を下回る申込先は従来どおりの審査（以下、通常審査）を行う。図2に示すとおり、信用スコアの閾値を引き下げれば、簡略審査が増え、手間とコストがかかる通常審査を減らすことができる。ただし、同時に、信用リスクの高い融資申込先に簡略審査を適用する可能性も高まる。信用リスクを抑えながら、簡略審査の割合を高めるためには、審査モデルの精度向上が不可欠である。




図1：モデルによる融資申込先のスクリーニング




図2：信用スコアの閾値と簡略審査の割合との関係

2. 先行研究

先行研究をみると、融資を実行したデータのみを用いて、デフォルトを被説明変数として信用スコアリングモデルを構築している。枇々木ら[2]は、教育ローンの承認先データを用いて、デフォルト（3カ月以上の延滞発生）の有無を被説明変数、属性情報（申込書の記入事項）、取引実績および個人信用情報を説明変数として、ロジスティック回帰モデルを構築し、AR値による評価とその有用性について実証した。引寺ら[1]は、教育ローンの承認先データを使用し、デフォルト（3カ月以上の延滞発生）の有無を被説明変数、属性情報（申込書の記入事項）、取引実績および個人信用情報を説明変数として、勾配ブースティングやランダムフォレストなど機械学習手法を使ってモデルを構築し、アルゴリズム間のAR値を比較検証している。

以上のように先行研究では、モデル構築において、承認先のデータしか用いていない。表1に示すとおり、融資申込先の中には、審査の結果、非承認となり融資に至らなかった先もある。非承認となった先は、申込時点で既に諸支払が大幅に延滞して

いるなど、モデル構築において重要な情報を有していると考えられるが、非承認先のデータを用いた先行研究はわれわれの知る限り存在しない。

表1：非承認先と承認先

| | | |
|-----------------------------------|------------------|--|
| 高 ↑ 信用 リス ク ↓ 低 | 非承認先 | 審査の結果、非承認となり融資しなかった先。例えば、申込時点で既に諸支払が大幅に延滞しているなど、仮に融資した場合、デフォルトする可能性が非常に高い先 |
| | 承認先 ² | 審査の結果、承認し融資した先 |
| | デフォルト先 | 融資後、返済が延滞した先 |
| | 非デフォルト先 | 融資後、正常に返済した先 |

表2：モデル構築に用いるデータ

| | 枇々木ら[2]、 引寺ら[1] | 本研究 |
|-------|--------------------|---------------------------|
| 使用データ | 承認先のみ | 融資申込先 (承認先および 非承認先) |

3. 本研究の概要

そこで、本研究では、非承認先の情報を利用することでモデルの精度を向上させることができないかと考えた。具体的には、表2に示すとおり、融資を承認した先のデータだけでなく、融資の承認に至らなかった非承認先のデータを用いることで、信用スコアの閾値を引き上げて簡略審査の割合を高めても、デフォルトする可能性の高い申込先が簡略審査と判定されにくいモデルの構築を目指す。

まず、融資申込先（承認先および非承認先）のデータを用いて、非承認を被説明変数としたロジスティック回帰モデル（以下、モデル①）と、デフォルトを被説明変数としたロジスティック回帰モデル（以下、モデル②）を構築する。次に、二つの回帰モデルの合成信用スコアを算出する。最後に、信用リスクが高い非承認先およびデフォルト先を通常審査と判定できる割合（以下、検出力）で合成信用スコアを評価する。

$$\text{検出力} = \frac{\text{分母のうち信用スコアの閾値以下の件数}}{\text{非承認先およびデフォルト先の件数}}$$

検出力は、簡略審査の割合ごとに算出する。比較対象は、先行研究と同じく承認先のみデータを使い、被説明変数をデフォルトとしたモデル②の信用スコアとする。

分析の結果、すべての簡略審査の割合において、合成信用スコアの検出力がモデル②の信用スコアを上回った。また、信用スコアの閾値を引き下げ簡略審査の割合を高めるほど、両者の差が大きくなることが確認できた。

4. 本研究で構築する2つのロジスティック回帰モデルの概要および信用スコアの合成方法

日本政策金融公庫国民生活事業本部が保有する2011年度から2017年度の教育ローンの融資申込先約77万件のデータを用いて2つのロジスティック回帰モデル(モデル①およびモデル②)を構築する。表3に概要を示す。説明変数は、先行研究と同様に、属性情報(申込書の記入事項)、取引実績および個人信用情報から200種類程度作成し、ステップワイズで絞り込んでいる。また、モデル②のデフォルトの定義は、融資時点から2年後の月末までにおける3カ月以上の延滞発生である。

合成信用スコアは、モデル①およびモデル②から算出された信用スコアを偏差値で標準化(平均50、標準偏差10)し、様々なウエイトで加算する方法で計算する³。

表3: ロジスティック回帰モデルの概要

| | モデル① | モデル② |
|----------------|---|---------------------------|
| 対象データ | 融資申込先 (承認先および 非承認先) | 承認先のみ |
| 被説明変数 | 非承認 | デフォルト (3カ月以上の 延滞発生) |
| 説明変数の数 | 18個 | 30個 |
| 説明変数の カテゴリー | <ul style="list-style-type: none"> ・属性情報(申込書の記入事項) ・取引実績 ・個人信用情報 | |

5. 合成信用スコアの検出力の検証

審査モデル高度化の目的は、簡略審査の割合を高めて審査コストを低減することにある。そこで、モデルの評価にあたっては、簡略審査の割合を任意に複数設定し、それに対応する信用スコアの閾値の検出力を用いる。たとえば、簡略審査の割合が75%となる信用スコアの閾値を算出し、その閾値に対する検出力を計算する。評価は、2つのモデルの信用スコアに対するウエイトの異なる複数の(4:1→1:4の7パターンに対する)合成信用スコアの検出力と、承認先のみデータを使用して被説明変数をデフォルトとして構築したモデル②の信用スコアの検出力との差を確認することによって行う。検証には、モデル構築に用いていない2018年度の融資申込先約12万件のデータを使用する。

表4に簡略審査の割合別にみた合成信用スコアの検出力を示す。検出力が最大となるモデル①とモデル②の信用スコアのウエイトは、簡略審査の割合ごとに異なる結果となった。合成信用スコアの検出力の最大値は、簡略審査の割合が25%のとき99.36%、同50%のとき96.45%、同75%のとき84.13%、同90%のとき59.94%となった。先行研究と同じく承認先のみデータで構築したモデル②の信用スコアと比較すると、簡略審査の割合が25%と低いときは検出力にほとんど差は見られ

ないが、同50%のとき+3.07ポイント、同75%のとき+9.72%ポイント、同90%のとき+14.12%ポイントとなり、簡略審査の割合を高めるほど、検出力の差が大きくなることが確認できた。

表4: 簡略審査の割合別にみた合成信用スコアの検出力

| モデル①と モデル②の 信用スコア のウエイト | 簡略審査の割合 | | | |
|----------------------------------|---------------|---------------|---------------|---------------|
| | 25% | 50% | 75% | 90% |
| 4:1 | 98.76% | 95.01% | 83.75% | 59.94% |
| 3:1 | 99.00% | 95.44% | 83.90% | 59.87% |
| 2:1 | 99.23% | 96.07% | 84.13% | 59.66% |
| 1:1 | 99.36% | 96.45% | 84.00% | 58.73% |
| 1:2 | 99.28% | 96.01% | 82.36% | 56.20% |
| 1:3 | 99.21% | 95.47% | 80.94% | 54.22% |
| 1:4 | 99.17% | 95.20% | 80.04% | 52.42% |
| 最大値 | 99.36% | 96.45% | 84.13% | 59.94% |
| モデル②の信用スコアとの差 | +0.61pt | +3.07pt | +9.72pt | +14.12pt |
| <比較対象> モデル②の 信用スコア | 98.76% | 93.38% | 74.41% | 45.82% |

注: 数字の下線付き太字は検出力の最大値を示す。

6. おわりに

本研究では、承認先だけでなく、非承認先を含めた融資申込先すべてのデータを用いることによって、教育ローン向け審査モデルの精度を向上させることができた。具体的には、先行研究と同じくデフォルトを被説明変数として構築したモデルの信用スコアだけでなく、非承認を被説明変数として構築したモデルの信用スコアを合成することで融資申込先に対するスクリーニングの検出力が高まることを確認した。

参考文献

- [1] 引寺佑輔, 尾木研三, 枇々木規雄(2021)「機械学習を用いた教育ローンのクレジットスコアリングモデル」, 公益社団法人日本オペレーションズ・リサーチ学会編『2021年春季研究発表会アブストラクト集』, pp. 234-235.
- [2] 枇々木規雄, 尾木研三, 戸城正浩(2011)「教育ローンの信用スコアリングモデル」, 日本金融・証券計量・工学学会編『ジャフィー・ジャーナル-金融工学と市場計量分析 パリビューション』, pp. 136-165, 朝倉書店.
- [3] 伏見多美雄, 福川忠昭, 山口俊和(1987), 『経営の多目標計画』, 森北出版.

¹ 本研究で示されている内容は筆者たちに属し、日本政策金融公庫としての見解をいかなる意味でも表していない。

² 承認先のなかには、承認後、資金が不要などの理由で融資申込を取り下げた先もあるが、先行研究および本研究の対象からは除外している。

³ モデル①とモデル②から算出された信用スコアの合成は、伏見ら[3]を参考に、加重和をとる方法のほか、低い方を採用する方法や高い方を採用する方法なども行った。紙面の都合上、検出力が最も高かった加重和をとる方法の算出結果を示す。