

小規模事業者向け信用スコアリングモデルの 予測精度向上に向けた軌跡 —大規模データからみえてきた小規模事業者支援の着眼点—*

日本政策金融公庫国民生活事業本部リスク管理部クレジットリスクマネージャー

戸 城 正 浩

専修大学商学部教授

尾 木 研 三

慶應義塾大学理工学部教授

枇々木 規 雄

要旨

日本政策金融公庫国民生活事業（以下、公庫）は、小規模事業者や創業企業への事業資金融資、一般個人への教育資金融資を通じて事業経営や国民生活の基盤を支えている。公庫は年間30万件にのぼる借入申込に対して迅速に必要な資金を届けるために、法人企業向け、個人企業向け、創業企業向け、教育資金融資向けの4種類の信用スコアリングモデル（デフォルト確率モデル）を金融工学の手法を用いて独自に開発し、運用している。しかし、公庫の主な融資先である従業者数9人以下の小規模事業者は、大企業や比較的規模の大きな中小企業に比べて、財務指標とデフォルトとの相関関係が弱い。そのため、小規模事業者向けの信用スコアリングモデルには、説明変数に財務指標を用いるだけでは、予測精度を高めるのが難しいという課題がある。

これを踏まえ、公庫は2003年度から財務指標に加えて属性情報を継続的に蓄積し、数多くの借入申込データを活用したモデル開発に取り組んできた。信用リスク管理を担う国民生活事業本部リスク管理部は2008年10月1日の創設以降、外部知見を取り入れたPDCAサイクルの体制を整備し、研究開発で得られた知見を速やかにシステムに実装し、モデルのバージョンアップを続けている。本稿は、国民生活事業本部リスク管理部が18年間にわたって実施してきた信用スコアリングモデルの予測精度向上に向けた軌跡をまとめ、豊富な借入申込データを用いた実証分析の結果を紹介することで、小規模事業者支援の着眼点を提示するものである。

* 本稿は、戸城正浩・尾木研三・枇々木規雄（2025）「信用スコアリングモデルの高度化に向けた軌跡—迅速な資金供給に向けて—」日本オペレーションズ・リサーチ学会『オペレーションズ・リサーチ』第70巻第8号、pp.383-390の内容を再編し、加筆修正したものである。本稿で示されている内容は、筆者らに属し、日本政策金融公庫としての見解をいかなる意味でも表さない。

1 はじめに

日本政策金融公庫は、国民生活金融公庫、農林漁業金融公庫、中小企業金融公庫を前身とする政策金融機関として2008年10月1日に発足した。国民生活金融公庫を前身とする国民生活事業（以下、公庫）は、小規模事業者（法人企業および個人企業）や創業企業への事業資金融資のほか、一般個人への教育資金融資を通じて、事業経営や国民生活の基盤を支えている。

公庫は、年間30万件にのぼる数多くの借入申込を受けるなか、信用スコアリングモデル（デフォルト確率モデル）を用いることで、個別企業の信用リスクを効率的かつ的確に評価し、迅速な資金供給を実現している。信用スコアリングモデルとは、主に財務指標とデフォルトとの相関関係を利用して個別企業の信用リスクを評価する統計モデルである。なお、本稿においては、デフォルトを借入金返済の3カ月以上延滞または倒産と定義する。ただし、教育資金融資について論じる第5節においては、別途定義する。

公庫では、金融工学の手法を用いて、法人企業向け、個人企業向け、創業企業向け、教育資金融資向けの4種類の信用スコアリングモデルを独自に開発し、運用している。公庫の主な融資先である従業者数9人以下¹の小規模事業者は、大企業や比較的規模の大きな中小企業に比べて、財務指標とデフォルトとの相関関係が弱い。そのため、小規模事業者向けの信用スコアリングモデルには、説明変数に財務指標を用いるだけでは、予測精度を高めるのが難しいという課題がある。

例えば、小規模事業者においては、経営者個人の資産や技能など、財務指標には表れない要素が経

営に与える影響が大きく、個別企業の信用リスクを計測することが難しいといわれている。さらに、小規模事業者は借入金額も小さく、柔軟な対応が可能なため、財務指標の悪化が直接的にデフォルトに結び付くとも限らない。こうした理由から小規模事業者向けの信用スコアリングモデルを財務指標だけで構築しても、満足のいく予測精度が得られないのである。

そこで公庫では、2003年度から財務指標に加えて、属性情報の蓄積を開始した。現在もこのデータ蓄積を継続している。

さらに、信用リスク管理を担う国民生活事業本部リスク管理部（以下、当リスク管理部）では、2008年10月1日の創設以降、外部の知見を取り入れた信用スコアリングモデルの予測精度向上に向けた研究開発を行うPDCAサイクルの体制を整備し、研究成果を速やかにシステムに実装するモデルのバージョンアップに取り組んでいる。

また、PDCAサイクルの一環として、モデルの客観性の確保と当リスク管理部における研究開発担当者の人材育成を実現するために、研究成果を学術論文としてまとめ、日本オペレーションズ・リサーチ学会や日本金融・証券計量・工学学会といった金融工学系の学会での発表や学会論文誌への投稿を継続してきた。

本稿では、当リスク管理部が18年間にわたって実施してきた、信用スコアリングモデルの予測精度向上に向けた軌跡について、法人企業向け、個人企業向け、創業企業向け、教育資金融資向けの四つのセクションに分けて、研究成果をまとめた論文とともに振り返っていく。

本稿の内容は、長年にわたり当リスク管理部が蓄積してきた信用スコアリングモデルの研究成果を体系的に整理し、大規模データからみえてきた

¹ 詳細は、日本政策金融公庫ホームページ（<https://www.jfc.go.jp/n/ir/disclosure.html>、確認日：2026年4月1日）を参照されたい。2024年度の事業資金融資の従業者規模別融資件数構成比は、4人以下が71.8%、5～9人が16.2%、10～19人が7.4%、20人以上が4.6%となっている。

小規模事業者支援の着眼点を提示するものである。小規模事業者への支援を行う金融機関の審査担当者の与信判断や、商工会議所・商工会、税理士事務所をはじめとした中小企業支援機関の担当者の支援業務の一助になれば幸いである。

2 法人企業向けモデル

(1) 研究の背景

本節では、法人企業向けモデルの研究成果について紹介していく。信用スコアリングモデルは主に、財務指標と、借入金返済の延滞や倒産といったデフォルトとの相関関係を利用して個別企業の信用リスクを評価する統計モデルである。公庫では、顧客への説明可能性の観点から、推定結果の導出過程がわかりやすいロジスティック回帰モデルを用いている。ロジスティック回帰モデルは、複数の説明変数から2値の結果(被説明変数)を予測するものである。被説明変数は、融資実行日から翌年度末までのデフォルトの有無としている。説明変数の回帰係数は、最尤法によって推定する。

モデル式は以下の(1)(2)のとおりである。 $Score_i$ は企業*i*の信用スコア、 PD_i は企業*i*のデフォルト確率、 n は説明変数の数、 a は定数項、 $x_{j,i}$ は企業*i*の説明変数 j ($j=1, \dots, n$)、 β_j は説明変数 j の回帰係数を表す。

$$Score_i = a + \beta_1 x_{1,i} + \beta_2 x_{2,i} + \dots + \beta_n x_{n,i} \quad (1)$$

$$PD_i = 1 / (1 + \exp(-Score_i)) \quad (2)$$

前述したとおり、公庫の主な融資先である従業者数9人以下の小規模事業者は、大企業や比較規模の大きな中小企業に比べて、財務指標とデフォルトとの相関関係が弱い。財務指標との相関関係が弱い主要因は、①会計監査を受けていない事

業者が多く、財務指標の精度が低いこと、②年1回だけの決算を行い、期中に試算表を作成していない事業者が多く、財務指標の即時性が低いこと、③所有と経営が分離されておらず、財務指標には表れない経営者個人の資産や負債の状況が、事業存続に大きな影響を与えていることである。

金融庁「金融検査マニュアル別冊〔中小企業融資編〕」(2015年1月)にも、「中小・零細企業の債務者区分の判断に当たっては、当該企業の財務状況のみならず、例えば、代表者の個人資産等も勘案して、その上で債務者区分を検討する必要がある」と記載されている。債務者区分とは、金融機関が融資先の財務状況、資金繰り、収益力などを総合的に評価し返済力を判定した分類である。実際、融資の現場でも小規模事業者においては、経営者の個人資産額が法人の債務超過額を大きく上回るケースや、法人では赤字を計上しているが、経営者の個人資産から借入金を返済しているケースは珍しくない。


(2) 経営者の個人資産額の

代理変数としての業歴の有効性

財務指標には表れない経営者の個人資産額を正確に把握するには時間とコストがかかる。モデルの予測精度を向上させるための情報収集に時間がかかったのでは、迅速な資金供給というモデル導入の目的と矛盾する。そこで、当リスク管理部では、多くの金融機関の実務において、人的審査を行う際に、個人資産額と一定の相関関係が期待できる定性的な評価項目として利用している業歴に着目した。

融資の現場での人的審査においては、財務内容が似通っている場合、業歴の長い事業者の方がデフォルトしにくいという経験則がある。ある程度の業歴があれば、経営者の個人資産の蓄積や、マネジメント経験や取引先とのネットワークといった経営ノウハウがあると考えられる。金融機関のベテランの審査担当者は、暗黙のうちに業歴を経営

図－1 業歴別デフォルト率



出所：枇々木・尾木・戸城（2010）（図－3 まで同じ）。
（注） σ は標準偏差。

者の個人資産額や経営ノウハウの豊富さを示す代理変数として用いてきた。業歴には、客観性があり外形的に把握しやすいという利点もある。

以上の議論を踏まえ、枇々木・尾木・戸城(2010)では、業歴に着目し、2004～2006年度に融資した法人企業約36万先のデータを用いて、業歴とデフォルトとの関係を明らかにするとともに、財務指標以外の説明変数として業歴を追加した信用スコアリングモデルを構築した。

枇々木・尾木・戸城（2010）では、業歴 n 年とは、事業を開始した後の営業を継続している期間が $n-1$ 年以上 n 年未満と定義する。ただし、 $n \geq 61$ は業歴60年とする。図－1に示した業歴とデフォルト率との関係をみると、一定の関連性がみえてくる。具体的には、業歴5年未満の企業のデフォルト率が最も高く、5年を経過して15年まで徐々に平均値まで低下し、35年まで安定的に推移する。35年を過ぎると緩やかに上昇し、50年を過ぎると再び低下する。このような傾向は融資年度を問わずみられる。

続いて、業歴区間ごとの特性について詳しくみてみよう。

① 業歴5年未満

デフォルト率は平均から 2σ 程度高い水準にある。とりわけ、2年以内のデフォルト率が高い。財務データを用いたスコアリングモデルで企業の信用力を評価することが難しい業歴区間であることがわかる。融資を行うときの条件として、「業歴2年以上（決算2期以上）」としている金融機関もあるが、2年を経過しても、依然としてデフォルト率が平均を 2σ 上回っており、信用リスクの高い時期がしばらく続くことがわかる。

② 業歴5年以上15年未満

徐々にデフォルト率が低下していく時期であるが、10年未満ではデフォルト率が平均を 1σ 程度上回る。事業が軌道に乗る時期であると同時に、軌道に乗り切れずに脱落する企業も少なくない。10年を過ぎると、デフォルト率が徐々に平均に近づいていく。

③ 業歴15年以上35年未満

デフォルト率が平均を下回り低位で安定している。事業が軌道に乗り、安定する時期といえる。

④ 業歴35年以上50年未満


デフォルト率が緩やかに上昇し始める。小規模事業者は後継者難という問題を抱えており、後継者不足による廃業や倒産によってデフォルト率が上昇している可能性がある。

⑤ 業歴50年以上

業歴50年ごろをピークに再びデフォルト率が低下に転じる。事業承継に失敗した企業が市場から退出したため、デフォルト率が低下している可能性がある。

以上のデフォルト率の形状（図－1）と業歴区間ごとの特性から、多項式関数（ n 次関数）をデフォルト関数として定式化を試みた。その結果、3次関

図－２ 年商規模別AR値



数で表せることがわかった。式は以下の(3)のとおりである。ここで、 y はデフォルト率、 x は業歴、 a_k は業歴の k 乗に対する回帰係数、 a_0 は定数項を表す。


$$y = a_0 + \sum_{k=1}^3 a_k x^k \quad (3)$$

次に、財務指標に加えて「業歴」「業歴の2乗」「業歴の3乗」を説明変数としたロジスティック回帰モデルを構築し、アウトオブサンプルデータである2007年度の法人企業への融資約11万件における予測精度を評価した。評価には、AR値(Accuracy Ratio)²を用いる。AR値は0～100%の値をとり、予測精度が高いほど100%に近づく。

年商規模別のAR値を図－2に、業種別のAR値を図－3に示す。濃い網掛けが財務指標だけを説明変数としたモデルの予測精度、薄い網掛けが業歴を加味したことによる予測精度の上乗せ部分である。

年商規模別のAR値をみると、どの規模でも業歴を加味することによって上昇しているが、財務指

図－３ 業種別AR値



標だけのモデルではAR値が低かった「5千万円未満」と「5千万～1億円未満」の層でとりわけ改善幅が大きく、年商規模間の格差が縮小している。次に業種別のAR値をみると、どの業種でも上昇しているが、比較的規模の小さな企業が多い「飲食店・宿泊業」と「サービス業」において改善が顕著で、業種間の格差も縮まる結果となった。

さらに、尾木・戸城・枇々木(2016b)は、2004～2011年度に融資した法人企業約109万先のデータを用いて、3次関数で近似した、業歴とデフォルト率との関係性が頑健であることを確認した。


(3) 業歴と経営者個人資産額との関係性

尾木・戸城・枇々木(2016b)は、2007～2010年度の個人企業、いわゆる自営業者への融資約32万件のデータを用いて、業歴別デフォルト率と資産保有額との関係も明らかにした。


図－4に業歴別にみた資産保有額(現預金保有額

² AR値の算出方法の詳細は、山下・川口・敦賀(2003)を参照されたい。


図－４ 業歴別の資産保有額とデフォルト率



図－6 業歴別のデフォルト率と不動産保有額との関係



図－5 業歴別のデフォルト率と現預金保有額との関係



および不動産保有額）とデフォルト率を示す。資産保有額は、業歴2年の金額を100として指数化している。資産保有額は、業歴が長くなるにつれて増加し、業歴20年では、現預金保有額は基準となる業歴2年の約2倍、不動産保有額は約3倍の水準となっている。このことから、業歴は、資産保有額と正の相関関係があることがわかる。一方、デフォルト率は、業歴が長くなるにつれて低下している。このことから、業歴は、デフォルト率と負の相関関係

係があることがわかる。

図－5に現預金保有額、図－6に不動産保有額について、業歴ごとにプロットしたデフォルト率との散布図、および回帰分析の結果を示す。R²（決定係数）は、現預金保有額で0.64、不動産保有額で0.65と比較的高い値を示していることから、資産保有額は、デフォルトを説明する変数として有効と考えられる。そして、図－4に示したとおり、資産保有額は業歴と正の相関関係がある。このことから、経営者の個人資産額の代理変数として、業歴を信用スコアリングモデルの説明変数に加えることは妥当であるといえるだろう。

（4）経営者の個人負債の有効性

戸城ほか（2024）は、2014～2018年度に融資した法人企業約46万先のデータを用いて、財務指標、業歴、業種に加えて、経営者個人の負債情報を説明変数に用いたモデル（以下、「新モデル」という）を構築し、当時運用していたモデル（以下、「旧モデル」という）を比較対象として、予測精度が大きく向上することを確認した。ここでいう経営者個人の負債情報とは、資金使途が住宅取得や教育費用である借入金残高や返済遅延の状況などである。

表－１ 旧モデルの使用データと説明変数

	使用データ	説明変数
基礎モデル	2007～2012年度の融資先84万229先	財務指標、業歴、業種
付加モデル	2011～2012年度の融資先12万7,086先	経営者個人の負債情報
旧モデル（統合モデル）	2011～2012年度の融資先12万7,086先	上記二つのモデルから算出される信用スコア

出所：戸城ほか（2024）（表－３まで同じ）

表－２ 新モデルの使用データと説明変数

	使用データ	説明変数
新モデル（単一モデル）	2014～2018年度の融資先46万4,869先	財務指標、業歴、業種、経営者個人の負債情報

旧モデルおよび新モデルの使用データと説明変数は、以下のとおりである。旧モデルは、表－１に示したとおり、基礎モデルと付加モデルを別々に構築し、両モデルから算出された信用スコアを説明変数として、再度モデルを構築することによって統合している。基礎モデルは、2007～2012年度に融資した法人企業約84万先のデータを用いており、財務指標、業歴、業種を説明変数としている。付加モデルは、2011～2012年度に融資した法人企業の一部約13万先のデータを用いており、経営者個人の負債情報を説明変数としている。

このように２段階でモデルを構築する手法を採用した背景は、旧モデルの構築当時、経年劣化のおそれを軽減し、モデルの頑健性を確保するためであった。すなわち、財務指標、業歴、業種については取得可能な６年間の長期間のデータを反映するとともに、データの蓄積を開始してから２年足らずの経営者個人の負債情報についても、一定程度、モデルに反映するためである。旧モデルでは、財務指標、業歴、業種と、経営者個人の負債情報について、回帰係数を同時に推定していなかったため、予測精度が高くなりにくいという課題があった。

一方、新モデルは、表－２に示したとおり、経営者個人の負債情報の蓄積が十分に進んだことから、財務指標と業歴、業種、経営者個人の負債情報について、回帰係数を同時に推定する単一のモデルを構築した。新モデルの構築には、2014～2018年度

に融資した法人企業約46万先のデータを用いた。

戸城ほか（2024）では、AR値を評価指標として新モデルと旧モデルの予測精度を比較することで、経営者個人の負債情報の有効性を確認した。使用したデータは、アウトオブサンプルデータを含む2014～2021年度に融資した法人企業約79万先である。表－３に示すAR値をみると、すべての融資年度において、新モデルが８ポイント前後上回っており、時系列でみても安定して優れていることがわかる。以上より、小規模事業者の信用リスクの評価において、経営者個人の負債情報の有効性が示された。

（５）コロナ禍データの活用の可能性

前述したとおり、信用スコアリングモデルは、財務指標とデフォルトとの相関関係を利用し、個別企業の信用リスクを評価する統計モデルである。しかし、新型コロナウイルス感染症の蔓延時（以下、コロナ禍）においては、政府による各種支援策によって小規模事業者のデフォルトが大幅に抑制された。これにより、財務指標とデフォルトとの相関関係が一時的に変化した可能性がある。コロナ禍後の融資におけるデフォルトを予測するモデルを新たに構築するうえで、このようなコロナ禍のデータを異常値として除外すべきか、それとも有効なデータとしてモデル構築に使用するインサンプルに含めるべきかが、金融機関にとって悩ましい問

表－3 新モデルと旧モデルのAR値

(単位: %、ポイント)

	融資年度							
	2014	2015	2016	2017	2018	2019	2020	2021
	新モデルのインサンプル (コロナ禍の影響なし)					アウトオブサンプル (コロナ禍の影響あり)		
新モデル	54.0	55.5	55.7	55.4	57.2	46.6	52.5	54.7
旧モデル	46.1	48.9	47.7	47.2	48.3	36.1	44.3	46.8
改善幅	+8.0	+6.6	+7.9	+8.2	+8.9	+10.6	+8.2	+7.9

題となっている。

そこで、長沼ほか（2025）では、コロナ禍を含む融資データを用いて、異なるインサンプル期間のデータを使用して複数のモデルを構築し、アウトオブサンプルにおける予測精度を比較、検証した。具体的には、戸城ほか（2024）が構築したモデル（以下、「ベースモデル」という）の説明変数をベースに、コロナ禍（2019～2020年度）を含む2014～2021年度の融資データを用いて、インサンプルのデータ時期を三つのアプローチに基づき、八つのパターンに分けた。そのうえで、パラメータを再推定し、新たなモデル（以下、「アップデートモデル」という）を八つ構築した。

ここでは、アウトオブサンプルである2022年度の融資データを用いて各モデルのAR値を比較することで、コロナ禍後の融資におけるデフォルトを予測する際に、コロナ禍のデータをモデル構築に使用するインサンプルに含めるべきか否かを議論する。

ベースモデルは、2014～2018年度に融資した法人企業約46万先をインサンプルデータとして、財務指標、経営者個人の負債情報、業歴、業種といった約200の変数を候補とし、カイ二乗検定の有意水準5%を基準としたステップワイズ法により、40の説明変数を採用している。

一方、アップデートモデルは、2014～2021年度に融資した法人企業約80万先を用いて、三つのアプローチに基づいて構築した。

一つ目は、モデル構築に使用するインサンプル期間をベースモデルと同じ5年間に固定し、2021年度まで1年ずつずらす「Rolling windows」である。

二つ目は、ベースモデルのインサンプル期間に2021年度まで1年ずつ追加する「Expanding windows」である。

三つ目は、コロナ禍（2019年度または2019～2020年度）を除外した期間をインサンプルデータとする「Excluding pandemic」である。

さらに、推定方法については、説明変数をベースモデルの40変数に固定して回帰係数だけを再推定する「Simplified process」と、説明変数の選択から行い、回帰係数を再推定する「Full process」の二つの方法でモデルを構築した。

表－4にSimplified process、表－5にFull processで構築したアップデートモデルについて、融資年度別でみたAR値を示す。表中において網掛けで示した融資年度が、各モデルを構築するときに使用したインサンプルデータ期間である。ここでは、すべてのモデルにおいて、アウトオブサンプルデータとなる2022年度の融資先の約7万先のAR値に注目して比較し、検証する。

表－4でSimplified processにより構築した各モデルの2022年度のAR値をみると、直近データをインサンプルデータに含むほど高くなる傾向を確認できる。例えば、Expanding windowsの三つのモデルをみると、2019年度までの融資先を含んだEW1が51.8%、2020年度までの融資先を含んだEW2が

表－４ AR値（Simplified process）

（単位：％）

アプローチ	ラベル	2014	2015	2016	2017	2018	2019	2020	2021	2022	平均
Base model	Base	54.0	55.5	55.7	55.4	57.2	46.6	52.5	54.7	51.6	53.7
Rolling windows	RW1	52.9	55.5	55.5	55.6	57.2	48.8	53.8	55.3	51.8	54.0
	RW2	52.2	53.8	54.9	55.3	56.9	51.2	57.6	56.3	52.0	54.5
	RW3	51.7	53.3	53.1	55.1	56.5	51.8	58.2	57.1	51.9	54.3
Expanding windows	EW1	53.9	55.6	55.5	55.5	57.1	48.9	53.7	55.3	51.8	54.2
	EW2	53.3	54.9	55.2	55.1	57.0	50.5	56.8	56.3	52.1	54.6
	EW3	53.5	54.9	55.0	55.1	56.7	50.7	57.0	57.1	52.4	54.7
Excluding pandemic	EP1	53.8	55.2	55.4	55.2	57.0	47.7	53.9	56.5	52.0	54.1
	EP2	53.6	55.0	55.1	55.2	56.9	49.4	56.7	57.1	52.2	54.6
n		91,530	93,246	97,727	94,471	87,895	87,920	157,551	88,623	70,246	—

出所：長沼ほか（2025）（表－５も同じ）

（注）網掛けは各モデルのインサンプル期間を示す（表－５も同じ）。

表－５ AR値（Full process）

（単位：％）

アプローチ	ラベル	2014	2015	2016	2017	2018	2019	2020	2021	2022	平均	変数
Expanding windows	EW3	57.1	58.7	58.8	57.9	60.2	54.1	60.7	60.8	55.4	58.3	66個
Excluding pandemic	EP2	58.9	59.8	59.7	58.8	61.4	49.5	57.0	60.9	55.0	57.9	67個
Base model	Base	54.0	55.5	55.7	55.4	57.2	46.6	52.5	54.7	51.6	53.7	40個

（注）Base modelはSimplified processの再掲。

52.1％、2021年度までの融資先を含んだEW3が52.4％と、より直近のデータを含めて構築したモデルほど高い。

また、2021年度の融資先を含んだExpanding windowsのEW3とRolling windowsのRW3を比べると、EW3（52.4％）の方がRW3（51.9％）より高い。直近のデータに絞るRolling windowsよりも、直近のデータを取り込み、なおかつデータ期間を長くにとってデータ数を増加させるExpanding windowsの方が予測精度が高いことを示す結果となった。

Full processで構築したモデルの結果をまとめた表－５では、表－４でAR値が相対的に高かったEW3とEP2の結果のみを示す。2022年度のAR値をみるとEW3が55.4％と最も高い。コロナ禍を除いたEP2はインサンプル期間のAR値が相対的に高いものの、2022年度のAR値は55.0％とEW3よりやや劣っている。以上より、変数選択を行った場


合でも、直近のコロナ禍のデータを取り込み、なおかつデータ期間の長いExpanding windowsのアプローチで構築したモデルが2022年度の融資先に対して高い予測精度を示す結果となった。

３ 個人企業向けモデル

（１）研究の背景

本節では、個人企業向けモデルの研究成果について紹介していく。個人企業は、法人企業が作成するような決算書はなく、その代わりとなる税務申告書においても、貸借対照表を作成していないケースもある。資産や負債に関する情報の開示にも消極的である。したがって、融資審査に当たっては、審査担当者による経営者からのヒアリングや提出書類、帳簿、通帳、借入金明細書などから資産や負

図－7 業歴別企業数



出所：尾木・内海・枇々木（2019）（表－7 まで同じ）

（注）個人企業は2007～2014年度に融資した先、法人企業は2004～2011年度に融資した先。

債に関する情報を把握し、貸借対照表を作成して評価している。

このように、個人企業は審査に手間とコストがかかるうえ、法人企業に比べて融資金額が小さく採算ベースに乗りにくいいため、信用スコアリングモデルの予測精度向上による審査業務の一層の効率化は金融機関にとって長年の課題となっている。

（2）業歴の有効性


尾木・内海・枇々木（2019）では、法人企業向けモデルにおいて有効性が確認できた業歴について、業歴別デフォルト率を定式化した業歴関数を個人企業向けモデルの説明変数にも投入することによって、予測精度の向上を試みた。分析で利用したデータは、公庫が2007～2014年度の8年間に融資した個人企業約68万先である。ここでは、特徴を比較するために、尾木・戸城・枇々木（2016b）の分析データ（2004～2011年度に融資した法人企業約109万先）および結果も併せて示す。

分析で利用したデータの業歴別の企業数を図－7に示す。業歴が長くなるほど個人企業数は減少する。業歴15年ごろから30年ごろにかけてややペースが遅くなるものの、業歴15年ごろまでと、業歴30年ごろから50年ごろにかけては、おおむね一定

のペースで減少する。創業時に個人企業であっても、業歴が長くなるにつれて法人化する企業が増えるため、個人企業数は一貫して減少する傾向にある。業歴15年ごろから30年ごろにかけては、法人化する企業が一段落するため、減少のペースが緩やかになるが、事業承継期もしくは廃業時期を迎える業歴30年以降は再び減少のペースが上がると思われる。一方、法人企業は、業歴10年ごろまで減少した後、しばらく安定した期間が続くが、業歴40年ごろから再び大きく減少する。なお、業歴が60年を超えると企業数が大幅に減少するため図－7では示していないものの、業歴100年以上の個人企業は3,500先程度存在する。

図－8は業歴ごとのデフォルト率を計算したグラフである。傾向をみるために、当該年および前後2年の5年間の値を平均した移動平均（太線）も示す。業歴とデフォルト率との関係を見ると、個人企業、法人企業とも業歴5年ごろまでは高く、業歴15年（個人1.64%、法人2.38%）でほぼ平均（同1.73%、2.30%）まで低下、その後も低下を続けて業歴25～35年ごろにかけてはおおむね横ばいとなる。その後、35年（同1.23%、1.93%）ごろから法人企業のデフォルト率は徐々に上昇し始め、45年（2.16%）を過ぎると再び低下する。一方、個人企業は40年を

図－8 業歴別デフォルト率



過ぎてもおおむね横ばいか、やや低下傾向にある。


以上より、個人企業においては、業歴5年まで急激に低下し、業歴25年ごろまで緩やかに低下、それ以降はほぼ横ばいという業歴区間ごとの特徴がみられる。これを踏まえて、図－9のような区分線形関数での定式化を試みた。

デフォルト率を区分する業歴は急激な低下が落ち着く t_1 年と、緩やかな低下が止まる t_2 年の2点とする。また、 t_2 年以降は関数ではなく定数とする。次に、 $t_1=2, \dots, 59$ 、 $t_2=3, \dots, 60$ の1,711通りについて、 t 年時点のデフォルト率 y_t を $\min(t-t_1, 0)$ と $\min(t-t_2, 0)$ で回帰し、最も決定係数の高い組み合わせを求める。具体的には以下の(4)の式のとおり、 y_t を区分線形関数で近似した $\hat{y}_t$ を求める。なお、業歴60年超については、業歴60年として扱う。

$$\begin{aligned} 1 \leq t \leq t_1 & \quad \hat{y}_t = b + a_2(t - t_2) + a_1(t - t_1) \\ t_1 \leq t \leq t_2 & \quad \hat{y}_t = b + a_2(t - t_2) \\ t_2 \leq t \leq 60 & \quad \hat{y}_t = b \end{aligned} \quad (4)$$

分析の結果、 t_1 年は4年、 t_2 年は25年の場合の修正 R^2 が0.929と最も高くなった。

図－9 個人企業の業歴別デフォルト率への区分線形関数の当てはめ



なお、デフォルト率は業種によって異なる(表－6)。「医療・福祉」「不動産業」「運輸業」については、修正 R^2 の値が低くなっている。次に、これらを除いた業種の t_1 の値をみると、製造業が8年である以外は4年前後が多い一方で、 t_2 の値は、20～47年とやや幅がある。 t_1 年から t_2 年にかけてはデフォルト率の低下が緩やかなため、どこから横ばいになるのかは微妙なところがあり、時系列的にやや不安定となっている可能性がある。

そこで、 t_1 、 t_2 の値を4年と25年で固定し、業種ごとに回帰係数を変えることにした。表－6で、 t_1 、 t_2 の値を4年と25年で固定した場合の修正 R^2 をみると、業種別に t_1 、 t_2 の年数を4年と25年で固定しても、修正 R^2 は大きく低下しないことがわかる。そこで、 t_1 、 t_2 の値は4年と25年で固定し、業種ごとに係数を変えた業歴関数をモデルに投入することにした。

そのうえで、説明変数を財務指標のみとした財務モデルと、財務指標のほかに業歴関数を加えた業歴モデルを構築し、財務モデルと業歴モデルの予測精度をAR値により比較した。モデル式は以下の(5)のとおりである。個人企業 i ($i=1, \dots, I$) につい

表－6 業種別区分線形関数の t_1 、 t_2 の分析結果

	製造業	建設業	卸・小売業	飲食店・ 宿泊業	医療・福祉	サービス業	不動産業	運輸業	その他
n	44,305	11,876	145,022	85,801	43,979	123,725	47,148	14,054	35,527
t_1	8	5	4	3	41	4	57	20	5
t_2	47	30	37	36	50	24	58	43	20
修正 R^2 (%)	57.5	82.4	83.4	86.7	12.7	66.6	17.2	11.6	62.0
修正 R^2 ($t_1=4, t_2=25$) (%)	54.9	81.3	82.3	84.5	－	66.6	－	－	60.8
差異 (ポイント)	-2.6	-1.1	-1.1	-2.2	－	0.0	－	－	-1.2

表－7 業歴モデルの推計結果および性能

業種	財務モデルの AR値 (%)	$\min(k_i-4.0)$ (γ_1)	$\min(k_i-25.0)$ (γ_2)	業歴モデルの AR値 (%)	改善幅 (ポイント)
製造業	38.6	0.24	0.01	40.2	+1.6
建設業	37.0	0.24	0.02	40.5	+3.5
卸・小売業	39.9	0.24	0.02	42.6	+2.7
飲食店・宿泊業 (年商規模：小)	36.1	0.24	0.03	42.0	+5.9
飲食店・宿泊業 (年商規模：大)	39.2	0.35	0.03	48.6	+9.4
サービス業 (年商規模：小)	41.4	0.24	0.01	41.8	+0.4
サービス業 (年商規模：大)	50.2	0.24	0.01	50.0	-0.1
その他	36.8	0.24	0.01	43.3	+6.5
全体	46.7	－	－	49.3	+2.6

て、財務変数 $x_{i,j}$ ($j=1, \dots, J$) と業歴 k_i ($k=1, \dots, 60$) を使用して、ロジスティック回帰モデルを構築し、最尤法によってパラメータ $\beta_j, \gamma_1, \gamma_2$ を推定することで、個別企業 i の信用スコア z_i 、デフォルト確率 p_i を算出する。

$$z_i = \ln\left(\frac{1-p_i}{p_i}\right) = a + \sum_{j=1}^J \beta_j x_{i,j} + \gamma_1 \times \min(k_i - 4.0) + \gamma_2 \times \min(k_i - 25.0) \quad (5)$$

業種別のAR値の改善幅は表－7のとおりである。「飲食店・宿泊業」「サービス業」については、年商規模によって特徴が異なる点を考慮して規模の大小で二つに区分している。改善幅は「飲食店・宿泊業 (年商規模：大)」で9.4ポイント、「その他」で6.5ポイント、「飲食店・宿泊業 (年商規模：小)」で5.9ポイントと大きくなっている。サービス業は

ほとんど改善しておらず、残りの業種も1.6～3.5ポイントと改善幅が小さい。ただし、業歴関数を投入したことによって、AR値の水準がすべての業種で40%以上となり、業種間の格差が解消されていることがわかる。

4 創業企業向けモデル

(1) 研究の背景

本節では、創業企業向けモデルの研究成果について紹介していく。わが国では、1980年代後半から開業率が低下し、ほかの主要先進諸国に比べて低い水準にあることから、政府は創業を増やすためにさまざまな支援策を打ち出し、金融機関も創業企業への融資を積極化している。公庫も、創業計画書の作成に対するアドバイスや創業に関

するさまざまな情報提供を行うとともに、年間約1万8千先におよぶ創業する前の企業への融資を行っている。

なお、本稿における創業企業とは、創業する前の企業と定義する。中小企業の信用リスク計測には、主に決算書の財務指標から信用リスクを数値化する信用スコアリングモデルが使われているが、創業企業には決算書がないため、既存のモデルは使用できない。そこで、当リスク管理部では公庫が融資した創業企業およびその企業の创业者の非財務情報を用いて、創業企業向けの信用スコアリングモデルの構築に取り組んでいる。

（２）人的要因、金融要因、業種要因の有効性

尾木・内海・枇々木（2017）は、2011～2013年度に融資した創業企業約3万4千先の非財務情報を用いて、ロジスティック回帰モデルを構築した結果、モデルの予測精度を評価するAR値は実務でも利用可能なレベルの57%を達成した。

被説明変数は融資後2年以内のデフォルトの有無とし、説明変数は①人的要因、②金融要因、③業種要因の三つのカテゴリーに分けて、詳細な分析を行った。なお、①人的要因および②金融要因の説明変数の分析においては、創業企業約3万4千先のうち業種と地域に比例して抽出したサンプル企業1,718先のデータを使用している。

① 人的要因

人的要因については、創業時の年齢（40歳未満ダミー）と斯業経験年数（5年以内ダミー）の有効性が明らかとなった。具体的には、創業時の年齢が40歳未満、斯業経験年数が5年を超える创业者は、デフォルト率が低い。斯業経験年数とは、これから創業する事業に関連する業種での勤務や経営の経験年数である。これから創業する事業に必要な知識、経験や体力などが创业者に備わっているかどうかを評価していると考えられる。

② 金融要因

金融要因については、创业者の創業前における資産負債状況の有効性が確認できた。すなわち、事業に投入する予定の自己資金も含めた金融資産の残高が多いほどデフォルト率が低く、住宅ローンといった金融負債の残高が多いほどデフォルト率が高い。金融負債の返済振りが良好な创业者はデフォルト率が低い。これは、创业者の資金調達力と計数観念の水準を表している。

③ 業種要因

業種要因については、付加価値率が高いか新規参入率が低い業種グループは回帰係数の符号がプラス（信用リスクが低い）、付加価値率が低い/new規参入率が高い業種グループは回帰係数の符号がマイナス（信用リスクが高い）で有意になった。ここでいう新規参入率とは、総務省・経済産業省「平成24年経済センサス—活動調査」による平成23年に開設した事業所数÷平成23年の事業所数である。付加価値率は、同じく付加価値額÷売上高である。表-8に、業種グループ別のデフォルト率の高低と、新規参入率、付加価値率をまとめた。これらをみると、付加価値率の高さと競争環境がデフォルトに影響していると考えられる。

（３）年齢、斯業経験年数、

創業の「旬」の有効性

尾木・峰下・枇々木（2023）は、2011～2018年度に融資した創業企業約10万8千先のデータを用いて、①創業時の年齢および②斯業経験年数と、デフォルトとの関係を詳細に分析するとともに、非線形関数を使った定式化を行った。さらに、創業時の年齢と斯業経験年数をクロスした分析の結果から③創業の「旬」の存在を示した。


これらを説明変数に投入したモデルを構築した結果、尾木・内海・枇々木（2017）が示したモデルと比較して、アウトオブサンプルデータのAR値が

表－8 業種グループ別の新規参入率と付加価値率

業種グループ（大分類ベース）	デフォルト率	新規参入率（％）	付加価値率（％）
宿泊業、飲食サービス業	高	4.5	44.0
サービス業（他に分類されないもの）	高	2.2	30.6
卸売業、小売業	高	2.0	10.4
生活関連サービス業	低	1.8	55.5
学術研究、専門・技術サービス業	低	2.4	52.6
医療、福祉	低	3.1	51.7
不動産業	低	0.5	31.2

出所：尾木・内海・枇々木（2017）

図－10 創業時の年齢別の融資先数構成比とデフォルト水準、4次関数で近似した曲線



出所：尾木・峰下・枇々木（2023）（表－9 まで同じ）

5.8～6.1ポイントも向上した。なお、②斯業経験年数および③創業の「旬」の分析においては、2017年1月～2019年3月に融資した創業企業約3万3千先のデータを使用している。

① 創業時の年齢


創業時の年齢別融資先数の構成比、デフォルト水準および4次関数で近似した曲線を図－10に示す。デフォルト水準は、全体のデフォルト率を1として指数化したものである。4次関数で近似した曲線をみると、32歳までデフォルト水準は低下し、その後39歳まではボトムで横ばいとなる。年齢が高くなるほど、知識や経験が豊富な創業者の割合が高まるためと考えられる。

40歳以降はデフォルト水準が上昇に転じる。変化への対応力や体力の衰えが影響していると思われる。その後、55歳をピークに緩やかにデフォルト水準が低下している。この点については、高齢になるほどリスクの高い創業に踏み切れない人の割合が増えるため、相対的にデフォルト水準が抑制されている可能性がある。

② 斯業経験年数

斯業経験年数でみた融資先数の構成比、デフォルト水準および2次関数で近似した曲線を図－11に示す。2次関数で近似した曲線をみると、18.51年でボトムとなっている。年数を重ねるほど、経験による学習効果が高まるためと考えられる。ボトム

図-11 斯業経験年数別の融資先数構成比とデフォルト水準、2次関数で近似した曲線



を過ぎるとデフォルト水準は上昇に転じる。勤め先の倒産やリストラなどで、やむを得ず創業した計画性の低い企業が増えている可能性がある。

③ 創業の「旬」

医療業や理・美容業といった専門性の高い国家資格が必要で、参入障壁が高い業種の場合、必然的に参入に必要な専門性が身についたベストなタイミングである「旬」で創業する人の割合が高くなり、その結果、デフォルト水準が低くなっていると考えられる。一方で、飲食店や小売業のように、資格が必要ない、もしくは短期間で取得できる業種は、参入障壁が低く競争が激しいため、知識や経験が不十分なまま創業して、激しい競争のなかで脱落する企業の割合が高くなり、デフォルト水準も高くなる傾向にある。

ただ、飲食店や小売業のなかにも、一定の経験を積んでのれん分けのようなかたちで創業する企業も一定の割合は存在し、そうした企業群はデフォルト水準が低い可能性がある。つまり、創業を意識しながら必要な知識と経験を積み、体力のあるうちに計画的に創業する企業は、デフォルト水準が低くなると想定される。

飲食店の創業時の年齢と斯業経験年数をクロス

したデフォルト水準を表-9に示す。デフォルト水準は飲食店全体のデフォルト率を1として指数化している。創業時の年齢が30～50歳、斯業経験年数が11～25年のゾーンにデフォルト水準の低い創業企業が集中していることがわかる。

特に、太枠で囲い、指数を大きく表示している部分（創業時の年齢が30～45歳、斯業経験年数が11～25年）は、デフォルト水準が0.5もしくは0.6で、飲食店全体のおおむね半分程度の水準となっている。まさに、ベストなタイミングである「旬」が存在していることがわかる。つまり、飲食店では、学校を卒業して11～25年の間、従業員として経験を積み、30歳代もしくは40歳代前半で創業する場合に最も信用リスクが低くなるといえる。

5 教育資金融資向けモデル

(1) 研究の背景

最後に、本節では教育資金融資向けモデルの研究成果について紹介していく。日本政策金融公庫国民生活事業本部生活衛生業務部「教育費負担の実態調査結果」(令和3年度)によると、子供1人当たりに必要な教育費用は、高校3年間で261.8万円、

表－9 飲食店の創業時の年齢と斯業経験年数をクロスしたデフォルト水準

		創業時の年齢							
		20歳～	25歳～	30歳～	35歳～	40歳～	45歳～	50歳～	55歳超
斯業経験年数	0年	3.4	2.2	1.0	0.7	1.6	1.2	1.7	0.7
	1～5年	2.1	1.2	1.0	0.9	1.4	0.9	1.2	0.8
	6～10年	1.4	1.4	0.8	0.8	1.1	1.4	1.3	1.7
	11～15年	—	1.0	0.5	0.5	0.7	1.1	1.1	1.9
	16～20年	—	—	2.3	0.6	0.6	0.9	0.9	2.9
	21～25年	—	—	—	1.6	0.5	0.9	1.8	0.6
	26～30年	—	—	—	—	0.5	1.5	1.0	2.3
	30年超	—	—	—	—	—	2.0	0.8	1.8

(注) 1 値は、飲食店のデフォルト水準を1としたときの各カテゴリーのデフォルト水準。

2 セル内のグラフが濃いものは構成比が1%以上、薄いものは構成比が1%未満、太枠で囲ったセルは創業の「旬」を示す。

表－10 進学先別融資件数構成比および平均融資金額（2021年度「国の教育ローン」）

進学先	大学	短大	専修学校	高校	外国の大学等	高専、大学院、その他	全体
融資件数の構成比 (%)	49.3	3.8	27.1	11.9	1.3	6.5	100.0
平均融資金額 (万円)	155	143	147	106	240	145	147

資料：日本政策金融公庫『日本政策金融公庫ディスクロージャー誌2022』

大学に入学した場合680.7万円が加わり、高校入学から大学卒業までに必要な入学・在学費用の合計は、942.5万円となる。高校卒業後の進学先別にみると、私立大学に入学した場合、文系で951.6万円、理系で1,083.4万円、国立大学では743.0万円となる。世帯年収に占める年間在学費用の割合は、平均で14.9%、年収階層別にみると、年収が低い「200万円以上400万円未満」の世帯では26.7%を占め、教育費用が保護者の経済的負担となっている。

資金使途を教育費用に特化させた融資商品が教育ローンであり、銀行をはじめとした数多くの金融機関が取り扱っている。主に保護者に対して、高校や大学などの教育機関に支払う入学金や授業料のほか在学に必要な教育費用（パソコン代や教科書代など）を融資している。融資の条件は金融機関によって異なるが、借入可能額は10万～1,000万円程度、返済期間の上限は10年程度で、在学中は利息のみの支払いが可能であり、元金の返済には据え置き期間を設けている。

公的機関では、公庫の「国の教育ローン」と独立

行政法人日本学生支援機構の奨学金がある。「国の教育ローン」は、1979年に「教育に関する家庭の経済的負担の軽減と教育の機会均等を図る」(日本政策金融公庫『日本政策金融公庫ディスクロージャー誌2022』)ことを目的に創設され、中学卒業以上の入学・在学資金を、主に保護者に融資する制度である。融資の対象となる条件として、扶養人数に応じて世帯年収の上限額を設けている。2021年度の融資件数は約9万件に上っている。一方で平均融資金額は、表－10のとおり、進学先別に異なるが、大学の場合でも155万円と、住宅ローンや事業資金融資と比べて小口となっている。

多くの借入申込に対して迅速に資金を供給するためには、信用スコアリングモデルを活用した効率的な審査プロセスが求められる。筆者らの知る限り、教育資金融資向けの信用スコアリングモデルに関する先行研究は、海外ではいくつか存在するが国内では存在しない。そこで、当リスク管理部では、公庫が保有する教育資金融資のデータを用いて、信用スコアリングモデルを開発した。

表－11 借入申込書の主な記入事項

融資申込人の家族状況	融資申込人と学生の続柄、扶養している子供の人数
収入	融資申込人の収入、同居家族の収入
職業	勤務先、雇用形態、勤続（営業）年数
住まい	居住年数、居住形態（持ち家、賃貸、社宅等）
借入	借入先、使いみち、残高、年間返済額

出所：枇々木・尾木・戸城（2011）（図－12も同じ）

（２）モデルの有用性

枇々木・尾木・戸城（2011）は、公庫の2005～2007年度の教育資金融資約28万件のデータを用いて、被説明変数に三つの観測期間（融資後2年以内、3年以内、4年以内）のデフォルト、説明変数に借入申込書の記入事項などを用いて、融資年度およびデフォルト観測期間ごとに複数のロジスティック回帰モデルを構築した。なお、ここでいうデフォルトとは3カ月以内の延滞を指し、以下断りのない限り、本節では同様に定義する。

モデル構築の結果、融資年度やデフォルトの観測期間が異なっても、選択される説明変数に大きな差異はみられなかった。モデルの予測精度を表すAR値も50％程度と実務で利用可能な水準に到達した。また、モデルの構築に使用していないアウトオブサンプルデータを用いた検証でも50％程度のAR値を維持できた。

表－11に、借入申込書の主な記入事項を示す。そのうちいくつかの事項について、デフォルトとの関係性を紹介する。①「融資申込人の収入」「同居家族の収入」は、高いほど相対的に返済負担が軽くなり、デフォルトしにくい、②「勤続（営業）年数」は、長いほど収入が安定し、デフォルトしにくい、③「居住年数」は、長いほど生活が安定しており、デフォルトしにくい、④「居住形態（持ち家、賃貸、社宅等）」は、持ち家がある方がデフォルトしにくい、⑤借入の「残高」や「年間返済額」は多いほど返済負担が重くなり、デフォルトしやすい。


（３）モデルの高度化

（否決先のデータの活用）

枇々木・尾木・戸城（2011）では、デフォルトの有無を判別するモデルを構築しているが、審査の結果、否決となった顧客のデータは、デフォルトの有無がわからないため、それを考慮したデフォルト評価モデルの構築および評価は行われておらず、審査で可決して融資した顧客である可決先のみのデータを用いてモデルを構築し、評価している。Jayadev, Shah, and Ravi (2021) は結論のなかで論文の限界として、対象とするデータが借入申込を承認された融資のみであることを挙げている。

一方で、デフォルトの有無がわからない否決先のデータを使った信用スコアリングモデルの研究は、リジェクト推論（reject inference）の分野で多く存在する。リジェクト推論は否決先のデフォルト率を推論する方法で、Nguyen（2016）は手法を五つ（①Manual estimation、②Similar in-house or Bureau data-based method、③Reweighting、④Extrapolation、⑤Heckman's two-step correction method）に分類し、それらの長所と短所を比較している。さらに、フランスの大手銀行のデータを用いて、五つのモデル（①KGB model、②Reweighting、③Parceling、④Fuzzy augmentation、⑤Heckman's bivariate two-stage model）に対する推定結果を示している。ただ、リジェクト推論によって、否決した顧客を考慮しない場合とは異なるパラメータが推定されることは示されているが、信用スコアリングモデルの予測精度を本当に改善できるかど

図-12 融資業務におけるモデルを用いた審査プロセス



うかはまだよくわかっていない。

一般的な実務においては、図-12のように信用スコアリングモデルを利用して計算されたスコアを用いて、審査を行い、可決・否決を評価する。そして、モデルで否決と評価されたスコアの低い顧客に対して、可決への変更を考慮して人的審査を行い、最終的に可決・否決を判断するというスキームを採用する金融機関が多くなっている。信用スコアリングモデルは否決先の顧客を考慮していないという問題点はあるものの、審査の効率性を高めるためにモデルを利用することの有用性は高い。

図-12に示したように、人的審査を経た場合を含めて可決した顧客は、返済能力が十分あり（家計収支の均衡がとれていて、諸支払いが正常に行われており）、審査時点ではデフォルトする可能性は低い顧客と評価されている。一方で、否決した顧客は返済能力が十分ではなく（家計収支が赤字で、諸支払いが正常に行われておらず）、審査時点ではデフォルトする可能性が高いと評価されている。そのように考えると、可決した顧客と否決した顧客は属性が異なる可能性が高い。

申込顧客には、否決先と同じ属性を持つ顧客も含まれる。可決先のデータのみで構築された信用スコアリングモデルでは、否決先のデータを反映していないため、すべての顧客に対して融資の可決・否決を審査するモデルとして活用するには不十分な可能性がある。筆者らの知る限りにおいて、

教育ローン向け信用スコアリングモデルの分野で否決先のデータをモデルの構築に使った研究は存在しない。

そこで、戸城ほか（2026）では、リジェクト推論の手法を参考にしつつ、融資の申込顧客（可決先および否決先）のデータを用いて可決・否決を被説明変数とする否決評価モデルと、可決先のみデータを用いてデフォルトの有無を被説明変数とするデフォルト評価モデルの二つのロジスティック回帰モデルを構築した。そして、デフォルト・非デフォルトを判別する要因と、借入申込の可決・否決を判別する要因に違いがあることを示し、否決先のデータを反映することの有用性を明らかにした。さらに、各年度における可決割合とデフォルト率との間に強い正の相関関係があることに基づき、人的審査で否決した先のデフォルト率は高いという仮定のもとで、否決先をデフォルト先として取り扱い、モデルの評価を行った。

モデルの構築には、公庫が取り扱う「国の教育ローン」の2011～2017年度の融資の申込顧客（可決先および否決先）約77万先を用いる。前掲表-11に示した借入申込書の記入事項およびクレジットヒストリーから作成した129個の変数を説明変数の候補として、カイ二乗検定の有意水準5%未満を基準にステップワイズ法により選択を行った。なお、デフォルト評価モデルの被説明変数であるデフォルトは、融資後2年以内で3カ月以上の延滞

表－12 候補として用いた説明変数のカテゴリーと項目および数

カテゴリー		項目	変数の数
借入申込書の 記入事項	申込人に 関する情報	職業（会社員、会社経営者、個人経営者など）	7
		収入の状況（年間収入や勤務・営業年数など）	3
		居住形態（自己所有、家族所有、賃貸など）	5
		家族の状況（家族の年間収入や扶養している子どもの人数など）	9
		学生との続柄（父母、本人など）	2
		在学先・進学予定先の学校の種別（高校、大学、専門学校など）	2
	借入条件に 関する情報	資金の使いみち（入学資金、在学資金など）	2
		借入条件（借入申込金額、申込日から借入希望日までの日数など）	3
		返済条件（返済期間、ボーナス時増額の有無など）	12
クレジットヒストリー	契約の状況（否決件数や借入件数、借入額や極度額など）	29	
	残債額の状況（返済額、残高など）	27	
	返済状況（事故情報の有無、返済遅延回数など）	28	
合計			129

出所：戸城ほか（2026）（以下同じ）

表－13 否決評価モデルとデフォルト評価モデルで選択された説明変数のカテゴリーと数

カテゴリー	否決評価モデル	デフォルト評価モデル	うち共通の変数
借入申込書の記入事項	3	11	1
クレジットヒストリー	15	18	4
合計	18	29	5

発生と定義する。

表－12に候補として用いた変数のカテゴリーと項目および数、表－13に各モデルで選択された変数のカテゴリーとその数を示す。二つのモデルで選択された変数は、重複を除くと合計で42変数である。ただし、両モデルの変数として選択されたのはそのうち5変数で、全体の11.9%（＝5変数÷42変数）にとどまっている。この結果は、否決先とデフォルト先では、審査時点での判別要因が異なることを示している。

否決評価モデルとデフォルト評価モデルの序列性を評価するために、モデル構築に使用したインサンプルデータ（2011～2017年度の約77万件）と、2018～2019年度およびコロナ禍の2020～2021年度の申込顧客約46万先をアウトオブサンプルデータとして用いて求めたAR値を表－14に示す。

否決評価モデルのAR値は、インサンプルで

83.67%、アウトオブサンプルで86～89%と高く、安定的に予測精度の高いモデルを構築できている。デフォルト評価モデルもインサンプルで61.73%、アウトオブサンプルで64～68%とある程度精度よく、安定的なモデルが構築できている。デフォルト評価モデルを使って可決・否決を評価したとしても、AR値は70～75%と高く、ある程度は審査に使えることがわかる。ただし、否決評価モデルの方がAR値は11～17ポイントも高く、可決・否決の特徴を捉えていることがわかる。


前掲図－12で示した審査プロセスにおいて、個別の申込顧客について、否決評価モデルとデフォルト評価モデルを用いて評価する。否決評価モデルから算出された否決スコア $Score_i^{NA}$ とデフォルト評価モデルから算出されたデフォルトスコア $Score_i^{DF}$ をどのように重視するかによって、申込顧客の評価値は異なる。

表－14 否決評価モデルとデフォルト評価モデルの精度評価（AR値）

（単位：％）

モデル		否決評価モデル		デフォルト評価モデル	
対象		否決	デフォルト	否決	デフォルト
インサンプルデータ		83.67	－	－	61.73
アウトオブ サンプル データ	2018年	88.50	37.58	71.74	65.11
	2019年	86.51	37.04	73.68	64.60
	2020年	86.51	41.92	74.79	65.73
	2021年	87.33	33.66	70.88	67.22

図－13 評価関数の無差別曲線

（注）CS_iは申込顧客の信用スコアCredit_Score_i。

そこで、戸城ほか（2026）では、多目標計画法で用いられる評価関数（伏見・福川・山口、1987）によって、申込顧客の信用スコアCredit_Score_iを算出する方法を提案した。本稿ではこのうち、否決スコアScore_i^{NA}とデフォルトスコアScore_i^{DF}の加重和で評価した場合を示す。ここでは、 w^{NA} は否決スコアの重み、 w^{DF} はデフォルトスコアの重みを表す。両スコアがこの重みで代替性を許す評価方法である。評価関数の無差別曲線（等高線）を図－13に示す。

$$\text{Credit_Score}_i = w^{NA} \cdot \text{Score}_i^{NA} + w^{DF} \cdot \text{Score}_i^{DF} \quad (6)$$

図－14にモデル構築に使用していないアウトオブサンプルデータである2018～2021年度の融資申込について、モデルの予測精度を表すAUC（Area Under the Curve）³の結果を示す。2018～2021年度のすべての融資申込において、否決スコアの重み（ w^{NA} ）とデフォルトスコアの重み（ w^{DF} ）が2：1と1：1の場合はほぼ同じ水準のAUCとなり、ほかの重みに比べて大きくなるとともに、比較対象のデフォルトスコアに比べて5.0～5.7ポイントと、5ポイントを上回る大幅な上昇が確認できた。このことから、否決先のデータを活用することの有用性が示された。

否決スコアがデフォルトスコアよりも重みが大い場合には、その重みが変わってもAUCにはそ

³ AUCの算出方法は山下・川口・敦賀（2003）を参照されたい。なお、AUCはAR値と線形の関係にある（AUC＝0.5×AR値＋0.5）。

れほど影響はないが、デフォルトスコアの重みが大きくなる場合には、徐々にAUCは悪化していくことがわかる。比較対象となるデフォルト評価モデルはその重みを無限大にしたものなので、この結果とは整合的であることがわかる。


6 おわりに

本稿では、当リスク管理部が、2008年10月1日の創設以降、18年間にわたって研究開発した、小規模事業者（法人企業および個人企業）および創業企業への事業資金融資および一般個人への教育資金融資向けの信用スコアリングモデルについて、研究成果をまとめた論文とともに振り返った。

誌面の都合上、紹介できなかったが、尾木・戸城・枇々木（2015）やToshiro, *et al.*（2019）は、デフォルト後の回収率を予測するモデルの研究、尾木・戸城・枇々木（2016a）は、信用スコアリングモデル（デフォルトを予測するモデル）とデフォルト後の回収率を予測するモデルを組み合わせた期待損失率（EL）を推計する研究、枇々木・尾木・戸城（2012）は、個別企業の信用リスクだけでなく、マクロファクター導入に向けた研究も行っている。また、最近のDXの進展を踏まえ、内海ほか（2021）や引寺・尾木・枇々木（2021）は、勾配ブースティングやランダムフォレストといったロジスティック回帰以外の手法を用いたモデル構築の研究、佐々木ほか（2023）では、銀行口座の残高や税金の支払状況といった新たな説明変数を追加したモデルの研究を行っている。

以上のように、当リスク管理部では、研究開発で得られた知見や成果を研究論文としてまとめたうえで、日本オペレーションズ・リサーチ学会や日本金融・証券計量・工学学会をはじめとした研究発表会で情報発信を行っている。このような学会活動を通して得られる外部有識者からの貴重なアドバイスは、われわれの研究開発に大いに役立って

図-14 AUC（Area Under the Curve）



いる。

さらに、論文にまとめる過程で、当リスク管理部の担当者のモデルへの理解がより深まるという効果がある。信用スコアリングモデルの予測精度を高めていくためには、人材の育成が必要不可欠である。引き続き、研究発表会での情報発信、学会への論文投稿、外部有識者との情報交換やディスカッションなどを通して、研究開発を担う人材を育成していきたいと考えている。

本稿の内容は、長年にわたり当リスク管理部が蓄積してきた信用スコアリングモデルの研究成果を体系的に整理し、大規模データからみえてきた小規模事業者支援の着眼点を提示するものである。小規模事業者への支援を行う金融機関の審査担当者の与信判断や、商工会議所・商工会、税理士事務所をはじめとした中小企業支援機関の担当者の支援業務の一助になれば幸いである。

<参考文献>

- 内海裕一・峰下正博・尾木研三・枇々木規雄 (2021)「創業企業の信用リスクモデルにおける人的要因の有効性—機械学習モデルとの比較—」日本オペレーションズ・リサーチ学会『2021年春季研究発表会アブストラクト集』pp.232-233
- 尾木研三・戸城正浩・枇々木規雄 (2015)「小企業向け保全別回収率モデルの構築と実証分析」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 ファイナンスとデータ解析』朝倉書店、pp.168-201
- (2016a)「小企業のEL推計における業歴の有効性」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 ファイナンスにおける数値計算手法の新展開』朝倉書店、pp.156-178
- (2016b)「小企業向け信用スコアリングモデルにおける業歴関数の頑健性と経営者の個人資産額との関係性」日本オペレーションズ・リサーチ学会『日本オペレーションズ・リサーチ学会和文論文誌』第59巻、pp.134-159
- 尾木研三・内海裕一・枇々木規雄 (2017)「創業企業の信用リスクモデル」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 リスク管理・保険とヘッジ』朝倉書店、pp.133-156
- (2019)「個人企業向けクレジットスコアリングモデルにおける業歴の有効性」統計数理研究所『統計数理』第67巻第1号、pp.121-149
- 尾木研三・峰下正博・枇々木規雄 (2023)「創業企業向け信用リスクモデルにおける人的要因の有効性—創業時の年齢、斯業経験年数、創業の『旬』の効果」日本金融・証券計量・工学学会『ジャフィー・ジャーナル』第21巻、pp.63-87
- 佐々木真佑・峰下正博・戸城正浩・尾木研三・枇々木規雄 (2023)「財務指標や基本属性以外の審査情報による小企業のデフォルト予測」日本オペレーションズ・リサーチ学会『2023年秋季研究発表会アブストラクト集』pp.96-97
- 戸城正浩・佐々木真佑・尾木研三・枇々木規雄 (2024)「小規模の法人企業向け信用スコアリングモデルにおける経営者個人の負債情報の有効性」日本オペレーションズ・リサーチ学会『2024年秋季研究発表会アブストラクト集』pp.66-67
- 戸城正浩・引寺佑輔・尾木研三・枇々木規雄 (2026)「否決先の情報を活用した教育ローン向け信用スコアリングモデル」日本金融・証券計量・工学学会『ジャフィー・ジャーナル』第24巻、pp.1-19
- 長沼大海・岩瀬優・戸城正浩・佐々木真佑・尾木研三・枇々木規雄 (2025)「ポストコロナ禍時代の小規模法人企業向け信用スコアリングモデルの構築—コロナ禍データ活用の可能性—」日本オペレーションズ・リサーチ学会『2025年秋季研究発表会アブストラクト集』pp.204-205
- 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」日本オペレーションズ・リサーチ学会『2021年春季研究発表会アブストラクト集』pp.234-235
- 枇々木規雄・尾木研三・戸城正浩 (2010)「小企業向けスコアリングモデルにおける業歴の有効性」津田博史・中妻照雄・山田雄二編『ジャフィー・ジャーナル—金融工学と市場計量分析 定量的信用リスク評価とその応用』朝倉書店、pp.83-116
- (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 バリュエーション』朝倉書店、pp.136-165
- (2012)「信用スコアリングモデルにおけるマクロファクターの導入と推定デフォルト確率の一致精度の改善効果」日本オペレーションズ・リサーチ学会『日本オペレーションズ・リサーチ学会和文論文誌』第55巻、pp.42-65
- 伏見多美雄・福川忠昭・山口俊和 (1987)『経営の多目標計画—目標計画法の考え方と応用例—』森北出版
- 山下智志・川口昇・敦賀智裕 (2003)「信用リスクモデルの評価方法に関する考察と比較」金融庁金融研究研修センター『Financial Research and Training Center discussion paper series』
- Jayadev, M., Neel Shah, and Vadlamani Ravi (2021) “Predicting Educational Loan Defaults: Application of Machine Learning and Deep Learning Models.” *IIM Bangalore Working Paper*, No.601

- Nguyen, Ha Thu(2016) “Reject Inference in Application Scorecards: Evidence from France.” *EconomiX Working Papers*, 2016-10
- Toshiro, Masahiro, Masao Tasaki, Yusuke Hikidera, and Norio Hibiki(2019) “Estimating the Recovery Rates for Unsecured Loans to Small Sized Firms.” *Asia-Pacific Journal of Risk and Insurance*, Vol.13(2), 20180029