

< 修 士 論 文 >

預金口座情報を用いた  
企業デフォルト予測の実証分析

滋賀大学大学院  
データサイエンス研究科  
データサイエンス専攻

修了年度：2020年度

学籍番号：6019113

氏 名：辻 和真

指導教員：田中 琢真

提出年月日：2021年1月20日

# 目次

## 1. はじめに

### 1.1 研究の背景

#### 1.1.1 中小企業金融

#### 1.1.2 スコアリングモデルとその課題

### 1.2 先行研究

### 1.3 方法

### 1.4 本論文の構成

## 2. データの概要

### 2.1 使用データ

#### 2.1.1 預金口座情報

#### 2.1.2 格付データ

#### 2.1.3 対象先

### 2.2 指標分析

#### 2.2.1 単独指標 AR 値

#### 2.2.2 ランダムフォレストによる指標重要度

## 3. モデル構築方法

### 3.1 データセットの分割方法

### 3.2 モデル評価方法

### 3.3 ランダムフォレスト

### 3.4 正則化ロジスティック回帰

#### 3.4.1 Lasso 回帰

#### 3.4.2 Ridge 回帰

## 4. モデル構築結果

### 4.1 預金口座情報モデル

### 4.2 金融機関格付との関係

### 4.3 統合モデル

## 5. 結論と今後の課題

### 5.1 結論

### 5.2 今後の課題

## 追加検証

1. データセット作成方法の変更
2. デフォルト観測期間の短期化

## 謝辞

## 参考文献

## 1. はじめに

### 1.1 研究の背景

#### 1.1.1 中小企業金融

「2020年版中小企業白書」(中小企業庁, 2020)によると我が国の企業の約99.7%が中小企業である。また、中小企業の従業者数は全体の約70%、付加価値額は約53%を占めており、中小企業は我が国の経済の柱である。我が国の経済全体の成長を促すには、中小企業が販路開拓や生産性の向上を目的とする成長投資を行うことが重要である。こうした成長投資においては、中小企業への適切な資金供給が欠かせず、それぞれが金融機関の重要な使命である。

しかしながら、中小企業向けの融資はいくつか課題を抱えている。日本銀行が公表する「全国企業短期経済観測調査」の資金繰りDI値を確認しても、中小企業の資金繰りは大企業と比較して厳しい傾向にあることが分かる。その要因として考えられるのが情報の非対称性である。金融機関が融資を行う際に重要となるのが借り手に関する情報である。この点、中小企業については、開示されている情報が限られていることから、大企業と比較して借り手と貸し手の情報の非対称性が大きくなりやすい。そのため金融機関においては適切な融資を行うために、担当者による企業訪問等を通じて、情報を得る必要がある。一方で、規模の小さな中小企業については融資金額が大企業と比較して小さく、その分金利収入も小さくなってしまい、採算性が見合わなくなる傾向にある。また、中小企業は規模が小さいため経営者の資質等に左右される要素も大きく、デフォルト率は大企業に比して大きい。中小企業庁が公開している「倒産の状況」によると2013年以降の倒産実績において中小企業の割合は各年度の平均で99.9%を超えている。金融機関は、融資した先がデフォルトすると融資金を回収することが難しくなり、損失が発生するリスク(信用リスク)を抱えている。採算性が低く、中小企業の審査に多額のコストをかけることが難しいこともあり、金融機関は融資金の回収可能性を高めるために経営者個人の担保や保証に依存した貸出姿勢がとられており、近年「日本型金融排除」として指摘されている(金融庁, 2016)。独立行政法人中小企業基盤整備機構が公表した「経営者保証ガイドラインアンケート結果」(2018)において、「経営者の個人保証を提供していますか?」という問いに対して8割を超える企業が「全てあるいは一部の借り入れに対して経営者の個人保証を提供している」と回答している。

#### 1.1.2 スコアリングモデルとその課題

上記のような中小企業に対する融資の課題を解決するための有力な方法がスコアリングモデルであると考えられる。スコアリングモデルとは、主に決算書等から得られる財務情報

から、統計的手法を用いて企業の信用力をスコア化(デフォルトを予測)するツールである。その歴史は古く、1950年代にはフェアアイザック社によって個人の信用リスクをスコア化するモデル「FICO スコア」が開発された。1960年代には企業の倒産予測モデルとして有名な Altman の Z スコア(Altman, 1968)などが発表された。また、我が国においては2003年に金融庁から「リレーションシップバンキングの機能強化に関するアクションプログラム」が発表されて以降広く浸透し、現在多くの金融機関では信用リスク管理においてスコアリングモデルが活用されている。財務指標等から得られる定量的な審査をスコアリングモデルによるスコアに基づいて行うことで、審査業務の効率化に繋がり、人的労力をかけるべき事業内容等の定性評価に時間をかけることができるようになり審査の高度化を図れる。さらに審査担当者の資質に左右されることなく審査基準の均質化、客観的指標の構築も実現できる。

しかしながら、平田(2005)でも指摘されているようにスコアリングモデルにもいくつかの問題点や限界がある。一つは決算書の情報に基づくことによる限界である。従来のスコアリングモデルでは決算書に現れる数字を基に企業のデフォルトを予測する。そのため、決算書に現れない実態財務や、定性情報については依然として審査担当者の判断が必要となる。また決算書に基づいてスコアを付与するため、当然悪意のある粉飾や偽装についてもモデルが見抜くことはできず、実態とは異なるスコアを付与することになる。加えて中小企業については決算書の信頼性に疑問がある可能性が指摘されている。「中小企業における経理財務における実態調査事業報告書」(中小企業庁, 2015)によると、中小企業における中小会計要領の認知度は25%程度である。加えて、経理財務担当の人員は、「1人」が最も多く58.2%、次いで、「2人」、「0人」と続いており、十分な体制を確保できている企業は少ない。また、決算書は多くの中小企業において年1回の作成となっており、情報の鮮度が低い。金融機関が審査時点で入手できるものは決算日から少なくとも3か月程度は経過していることがほとんどであり、その情報が次に更新されるのはおよそ1年後になる。他にも、スコアリングモデルは実際に融資を実行した企業のデータを利用して構築されることが多いことからサンプル・バイアスの問題も生じうる。理想を言えば、融資を謝絶した先を含めたデータを使い、モデルを構築することが望ましいとされる。海外では、モデルの精度を維持するためのコストとして毎年、本来は謝絶すべき先に融資してデータを取得している金融機関もあると言われている。ただし、サンプル・バイアスの影響を考慮した研究としては Crook et al. (2004)があり、その影響はあまり大きくない可能性が示されており、また、国内においてもバイアスによって問題が生じたという報告や指摘は聞かれない。

スコアリングモデルにはこうした課題が挙げられているものの、低金利環境が継続し、金融機関の貸出競争が激しさを増していく中、スコアリングモデルを活用した信用リスク管理の高度化は重要な課題である。モデルに基づき信用リスクを適切に把握することができれば、融資先のモニタリングはもちろん、リスクに応じた金利を設定することで採算性を改善でき、融資対象を拡大することも考えられる。

本研究では、従来のスコアリングモデルにおいて十分に活用されてこなかった預金口座情報について、企業のデフォルト予測への活用を試みる。預金口座情報を活用することの利点については以下の四点が考えられる。第一に情報取得の迅速性、第二に情報の取得コストが小さい点、第三に情報の信頼性、そして最後に情報の独自性である。

まず、情報取得の迅速性について、決算情報では、上述したように多くの中小企業では年に一度しか決算書は作成されず、金融機関が決算書を受け取り、最新の財務情報をスコアリングモデルに反映するまでに数か月のタイムラグが発生する。わずかな変化がデフォルトに繋がる可能性のある中小企業に対しては、少しでも早い信用情報の更新が理想的である。上場企業であれば、四半期ごとの開示が義務付けられており、業績や財務情報を含めた市場の評価が株価などに先行指標として現れるが、中小企業にはこうした先行指標はない。この点、預金口座情報は口座取引が発生するたびに即座に銀行にデータとして蓄積されていくものである。このデータを活用すれば、方法によっては、日次ベースあるいはリアルタイムで企業の信用スコアを更新していくことも可能であると思われる。

次に取得コストであるが、預金口座情報は金融機関の預金業務においてシステムによって自動的にデータの生成、蓄積されていく。金融機関からすればデータを取得するために担当者が企業へ訪問する必要も無く、企業からしても金融機関の審査のために会計情報等の集計や資料作成をする必要がない。金融機関、企業双方にとって追加的なコストが発生しない点は非常に大きなメリットであると言える。

当然、預金口座情報は実際の入出金取引の記録に基づいて金融機関のシステムにおいて作成されることから融資先による改ざんは難しく、データの信頼性は非常に高い。

最後に情報の独自性であるが、決算情報は決算書を受け取ればそれまで全く取引がなかった金融機関においても、長年取引を継続してきた金融機関と同一の情報を取得することができる。一方で、預金口座情報は取引がある金融機関しか把握することができない独自の情報であり、有効に活用することができれば他の金融機関との差別化にもつながり、競争力が高まると考えられる。

以上のように預金口座情報をスコアリングモデルに活用することには様々な利点がある。しかしながら、近年いくつかの研究が報告されているもののその数は少なく、預金口座情報のスコアリングモデルへの活用はあまり進んでいない。これは決算書を用いた財務情報に基づく信用リスク評価については過去から研究がなされてきていることと対照的である。例えば財務情報を用いた研究では藤井他(2010)は中小企業の大規模な財務情報を使い、スコアリングモデルを構築し、デフォルト確率の推定とその期間構造に関する実証分析等を行っている。また、財務情報については「自己資本比率(資本金/総資産)」や「デットキャパシティーレシオ(負債総額/自己資本)」などの企業のデフォルト予測に有効な指標等の知見も確立されている。一方で預金口座情報については、有効な指標等は明確に定まっていない。加えて決算書と異なり、預金口座情報は対象の企業に関して網羅的な情報ではない可能性が考えられる。例えば複数の金融機関で取引をしている企業であれば、単一の金融機関が利

用できる情報はその企業の取引の一部になる。このように、預金口座情報をスコアリングモデルに活用するためには解決すべき課題も多い。

## 1.2 先行研究

次に預金口座情報を用いたデフォルト予測についての先行研究を紹介する。

海外においては Yao et al. (2017) がフランスの企業に対し、預金口座の入出金情報を用いることで従来の財務情報に基づく手法よりも高い精度を示したとしている。

国内においては、三浦他(2019)がりそな銀行の実データを利用して、入出金データを用いたデフォルト予測モデルの構築を行った。入出金データには月次単位で過去 24 か月分のデータを利用している。取引の性質を示す摘要グループで入出金取引をグルーピングし、各取引金額および取引回数を集計したものに、預金残高(月中平残)を加えたベース指標を作成。さらにベース指標を加工した指標を作成し、これらを用いて特定の期間内にデフォルトする企業を予測するモデルを構築している。モデル構築手法にはランダムフォレスト、勾配ブースティングツリー、ロジットモデルを利用しており、いずれのモデルにおいても十分な精度のモデルが構築できたことを報告している。加えて、財務スコアと組み合わせた結果、精度が改善し、良好な結果を示した。また、デフォルト予測に有効な指標は「預金残高」や「出金返済」に関する指標であるとしている。本研究は、三浦他(2019)の手法を参考としているが、預金口座情報のみから作成できる指標のみを利用している点や預金残高や入出金取引の金額自体を利用していない点が異なる。

根本他(2019)は企業の銀行口座動態情報に対して主成分分析を利用することで、デフォルト予測に有効な指標を作成できることを示した。また、財務モデルと銀行口座動態情報に基づくモデルの示す信用力には相関関係があること、ケースによっては銀行口座動態情報のみを使用したモデルでもデフォルト推計の正確性は財務モデルと大きく変わらないことを実証した。企業ではなく個人を対象とした研究では、上武他(2020)がカードローン利用者を対象とし、入出金の取引金額の情報に加え、入出金の内容から推測される個人の行動特性を考慮に入れたデフォルト予測モデルを構築し、十分な精度が得られたことを示している。

いずれの研究においても預金口座情報を利用することがデフォルト予測において有効な手段であると結論している。

## 1.3 方法

本研究は中小企業に対するデフォルト予測について預金口座情報の有効性を実証するものである。手法については三浦他(2019)を参考に、預金口座情報(預金残高データおよび入出金データ)から作成した指標を用いてモデル構築を行った。モデルの構築手法としては、ランダムフォレストおよび正則化ロジスティック回帰(Lasso 回帰, Ridge 回帰)を使用した。

分析の結果として、財務情報をベースとした現行の金融機関格付には及ばないものの、預金口座情報のみを利用し、実用に耐えうる精度のモデルが構築できた。また、実務での展開を考慮し、金融機関における格付を組み合わせたモデルについても検証を行い、予測精度が向上したことから、預金口座情報の活用がデフォルト予測に有効であることが確認できた。

## 1.4 本論文の構成

本論文の構成は以下の通りである。まず、2節で使用するデータの概要について述べる。3節では、構築するモデルの概要とその検証方法を示す。4節では、構築したモデルの結果を示す。最後に5節で分析を通じて得られた結果の考察及び今後の検討課題について整理する。

## 2. データの概要

本節では、使用したデータの特徴および加工方法について説明する。

### 2.1 使用データ

本研究では滋賀銀行が保有するデータを使用する。使用するデータは協定と秘密保持契約に基づき、個々の口座を特定の企業と識別できないように加工した形で滋賀大学に提供された「預金口座情報」および企業のデフォルトを判別する「格付データ」である。預金口座情報から作成した指標を用いて、デフォルトする企業を予測するモデルを構築する。対象先については基準月時点で滋賀銀行の格付が付与されている中小零細企業とした。なお、中小企業の定義は中小企業基本法に基づき、「業種」、「資本金」、「従業員数」によって定まる。零細企業については中小企業の定義によらず、年商3億円未満の企業とする。本研究における対象となる企業数はおよそ10,000先である。

表1 中小企業の定義

業種分類	中小企業基本法の定義
製造業その他	資本金の額又は出資の総額が3億円以下の会社又は常時使用する従業員の数が300人以下の会社及び個人
卸売業	資本金の額又は出資の総額が1億円以下の会社又は常時使用する従業員の数が100人以下の会社及び個人
小売業	資本金の額又は出資の総額が5千万円以下の会社又は常時使用する従業員の数が50人以下の会社及び個人
サービス業	資本金の額又は出資の総額が5千万円以下の会社又は常時使用する従業員の数が100人以下の会社及び個人

## 2.1.1 預金口座情報

本研究において対象とした預金口座は流動性預金(普通預金, 当座預金)とし, 1つの企業について複数の口座があればすべて合算して扱った. 預金口座情報として使用するの「預金残高データ」と「入出金データ」である. 各データを加工して「項目」を作成し, 各項目を加工することでモデル構築に利用する「指標」を作成する. 預金残高データからは企業ごとに保有する預金口座の月次の「月中平残」, 「月末残高」を項目として利用する. 入出金データは預金口座の入出金取引の全明細であり, 「顧客 ID」, 「取引日時」, 「取引金額」, 「入出金区分」, 「摘要コード」から構成される. 「顧客 ID」は各企業に付与される一意の番号である. まず, 「取引日時」から「取引年月」を作成し, 「入出金区分」および「摘要コード」からその性質に応じてグルーピングし, 10 個の「項目」を作成した. 続いて, 「取引年月」, 「顧客 ID」および「項目」を用いて「取引金額」を月次単位で集計し, 預金残高データと入出金データを合わせ債務者ごとに月次で 12 個の項目を持つデータを作成する. 預金口座情報の項目についてまとめたものを表 2 に示す. 債務者ごとに各時点における直近過去 6 か月分のデータを結合して, 「月次預金口座情報データ」を作成した.

表 2 預金口座情報の項目

集計単位	元データ	区分	項目	主な摘要コード
月次	入出金データ	入金額	売上	振込、現金
			融資	融資
			入金投資	投資信託、配当金
			入金その他	利息、口座間振替
		出金額	原価	振込
			出金投資	投資信託
			変動費	税金
			固定費	光熱費、家賃
	預金残高データ	預金残高	返済	返済、割引料
			出金その他	現金、口座間振替
			月末残高	—
			月中平残	—

月次預金口座情報データを用いて, 各項目の「前月比」, 「月中平残比」を作成し, 指標とした. 12 項目について過去 6 か月のデータを利用して作成するため, 「前月比」は,  $12 \times (6 - 1) = 60$  指標, 「月中平残比」は  $(12 - 1) \times 6 = 66$  指標となる. さらにそれらの指標の項目ごとの「期間平均」, 「期間標準偏差」を作成し, 指標に追加した. ここで, 各指標の「月中平残比」については, 企業の規模による金額の大小の影響を削減する基準化の効果が期待される. 財務指標においても「総資産回転率(売上高/総資産)」や「売上高当期純利益率(当期純利益/売上高)」といった比率を利用することが多い. この点, 三浦他(2019)では「融資残高」, 「売上高」, 「総資産」といった決算書などから得られるデータを用いて入出金金額について基準化を行っている. 根本他(2019)においても「融資残高」,

「売上高」を利用している。しかしながら、預金口座情報については、企業ごとに複数の金融機関を利用している可能性が考えられることから、一つの金融機関が預金口座から取得できるデータはその企業の預金取引を網羅的に扱うものではなく、断片的になっている場合がある。つまり、決算書から得られる会社の情報と、口座から得られるデータに整合性が有るとは限らず、入出金情報の規模を把握するには、預金口座から取得できる情報が有用であると思われることから、本研究では「月中平残」を基準化に利用した。さらに、単純に金額の大小で判別が行われること(例えば預金残高が多いから信用度が高いとみなすこと)は小規模企業の信用判断には望ましくないと考えられることから、金額そのものは指標として扱わないこととした。よってモデル構築に利用する預金口座情報の指標は以下の 172 指標となる(表 3)。

表 3 預金口座情報における指標一覧

NO	加工方法	項目数	期間	指標数
①	項目の前月比	12	5	60
②	①の期間平均	12	1	12
③	①の期間標準偏差	12	1	12
④	項目の月中平残比	11	6	66
⑤	④の期間平均	11	1	11
⑥	④の期間標準偏差	11	1	11
合計				172

## 2.1.2 格付データ

格付データは「基準年月」、「顧客 ID」および「格付」によって構成されており、月次単位のデータである。まず、今回の研究におけるデフォルトの定義について説明を行う。一般的にデフォルトは債権の元金金の支払が期日内または猶予期間内になされない場合や、債務者が破産するなどして、債務が履行できなくなる状態を指す。しかしながら、銀行実務においては定義が異なる。金融機関は審査に基づき、各債務者に対して格付を付与する。格付は金融機関によって違いはあるものの、概ね 10~17 程度に区分を行っており、この格付に基づいて債務者を「債務者区分」という「正常先」、「要注意先」、「要管理先」、「破綻懸念先」、「実質破綻先」、「破綻先」の 6 つの区分に分類する。例えば格付が 11 区分であれば、格付が 1~6 なら「正常先」、7 なら「要注意先」、8 なら「要管理先」、9 なら「破綻懸念先」、10 なら「実質破綻先」、11 なら「破綻先」といった形になる。各債務者区分の定義については表 4 の通りである。銀行実務上は「要管理先」以下をデフォルトとして扱うことが多いが、一般的なデフォルト定義に近いと思われるのは「破綻懸念先」以下である。よって本研究においては、デフォルトについて 2 つの基準を用い、「要管理先」以下あるいは「破綻懸念先」以下をデフォルト先と定義してモデル構築を行う。以降、各基準以下の格付が付与された先を「デフォルト先」、それ以外を「非デフォルト

先」と呼ぶ。つまり要管理先基準であれば非デフォルト先は「正常先」、「要注意先」、デフォルト先は「要管理先」、「破綻懸念先」、「実質破綻先」、「破綻先」であり、破綻懸念先基準であれば非デフォルト先は「正常先」、「要注意先」、「要管理先」、デフォルト先は「破綻懸念先」、「実質破綻先」、「破綻先」となる。

表4 債務者区分の概要 金融検査マニュアルより

債務者区分	概要	対応格付例
正常先	業況が良好であり、かつ、財務内容にも特段の問題がないと認められる債務者。	1～6
要注意先	金利減免・棚上げを行っているなど貸出条件に問題のある債務者、元本返済若しくは利息支払いが事実上延滞しているなど履行状況に問題がある債務者のほか、業況が低調ないしは不安定な債務者又は財務内容に問題がある債務者など今後の管理に注意を要する債務者。	7
要管理先	要注意先の債務者のうち、当該債務者の債権の全部又は一部が要管理債権である債務者。	8
破綻懸念先	破綻懸念先とは、現状、経営破綻の状況にはないが、経営難の状態にあり、経営改善計画等の進捗状況が芳しくなく、今後、経営破綻に陥る可能性が大きいと認められる債務者（金融機関等の支援継続中の債務者を含む）。	9
実質破綻先	実質破綻先とは、法的・形式的な経営破綻の事実は発生していないものの、深刻な経営難の状態にあり、再建の見通しが無い状況にあると認められるなど実質的に経営破綻に陥っている債務者。	10
破綻先	破綻先とは、法的・形式的な経営破綻の事実が発生している債務者をいい、例えば、破産、清算、会社整理、会社更生、民事再生、手形交換所の取引停止処分等の事由により経営破綻に陥っている債務者。	11

格付データにおいて予測基準月時点で非デフォルト先であり、デフォルト観測期間内にデフォルト先に変化した先にデフォルトフラグを設定する(例：デフォルト観測期間を12か月、予測基準月を2019年4月とすれば、2019年4月に非デフォルト先であり、2020年4月までのいずれかの月にデフォルト先に変化した先)。本研究においては、予測基準月の預金口座情報を用いてデフォルト観測期間中にこのデフォルトフラグが発生する先を予測するモデルを構築する(図1)。なお、預金口座情報観測期間は6か月、デフォルト観測期間は12か月と設定する。



図1 預金口座情報観測期間とデフォルト観測期間

### 2.1.3 対象先

以上の方法を用いてデータを作成した結果、各デフォルト基準における対象先数およびデフォルト先数については表5の通りである。

表5 対象先の概要

予測基準月	デフォルト基準	対象先数	デフォルト先数	デフォルト率
2019/3~2019/10	要管理先	70,915	858	1.21%
	破綻懸念先	71,216	610	0.86%

## 2.2 指標分析

上述したデータを用いて入出金モデルの構築を行っていくが、入出金データについては財務指標のような有効な指標は確立されていない。そのため最初に全データを用いて①単独指標 AR (Accuracy Ratio) 値および②ランダムフォレストによる指標重要度の算出を行い指標の有効性の特徴を確認する。

### 2.2.1 単独指標 AR 値

単独指標 AR 値は、その名の通り単独の指標ごとに AR 値を算出したものである。AR 値とは指標値や信用スコアとデフォルトした先の序列性(悪い先をより悪く、良い先をより良く評価できているか)を測る統計量である。AR 値は $-1 \sim 1$ の値をとり、1に近いほど、デフォルト先について序列性をもって評価できており、0であればランダムモデルとなる。AR 値は AUC (Area Under the Curve) とほぼ同義であり、 $AR = AUC \times 2 - 1$  で算出することができる。AR 値については山下他(2011)が詳しい。なお、本研究で構築するモデルの精度を評価するためにも AR 値を利用する。

単独指標 AR 値については単純に当該指標が大きければ大きいほど、あるいは小さければ小さいほどデフォルトしやすい傾向があることを想定して算出している。ここで、指標によっては一方向にならない指標も存在する可能性がある点には留意が必要である。例えば財務指標であれば、「売上債権回転期間((売掛金+受取手形)/(売上高/12))」のような指標についてはその指標が大きすぎても(資金繰りが繁忙)、小さすぎても(そもそも信用が無い)デフォルトしやすいことを示していると考えられる指標もある。

単独指標 AR 値の上位 50 指標について結果を表6に示す。なお、1つも上位指標に含まれなかった項目については表中への記載を省略している。要管理先基準および破綻懸念先基準のどちらでも上位に含まれた項目に違いはなく、出金区分は全ての項目が含まれていたものの、入金区分では「売上」の項目のみが含まれた。加工方法では「月中平残比」が多く含まれた。この点、月中平残に比して入出金の金額が大きいということは資金繰りが逼迫

している可能性が考えられるため、実感覚とも整合的であると思われる。また、単月の指標ではなく平均や標準偏差といった指標が多くを占めており、デフォルトする企業の特徴については特定月の情報ではなく中期的な預金口座情報の傾向として現れている可能性が考えられる。

表 6 単独指標 AR 値上位 50 指標

要管理先基準				破綻懸念先基準			
項目	指標数	加工方法	指標数	項目	指標数	加工方法	指標数
売上	8	月中平残比	42	売上	9	月中平残比	39
原価	8	前月比	8	原価	8	前月比	11
出金投資	10	合計	50	出金投資	7	合計	50
固定費	1			固定費	2		
返済	9			返済	9		
出金その他	8			出金その他	9		
月末残高	4			月末残高	4		
月中平残	2			月中平残	2		
合計	50			合計	50		

## 2.2.2 ランダムフォレストによる指標重要度

次に全データを用いてランダムフォレストモデルを構築し、その指標重要度を算出した。指標重要度の上位 50 指標を集計した結果を表 7 に示す。上位指標に含まれた項目は単独指標 AR 値と大きな変化はなかったものの、「月末残高」や「月中平残」の指標が多く選択された。特に破綻懸念先基準では、「月末残高」項目を加工した 15 指標すべてが上位に入った結果となった。加工方法では、単独指標 AR 値と同様に「月中平残比」の指標が「前月比」よりも多く含まれたが、「前月比」指標が大きく増加した。このことは「前月比」の指標については単純な大小関係ではないものの、デフォルト判別に一定の有効性があると思われる。入出金額や預金残高の前月比が変動する企業については受注状況や資金繰りが安定しておらずデフォルトしやすい可能性が考えられる。

表 7 ランダムフォレストによる指標重要度上位 50 指標

要管理先基準				破綻懸念先基準			
項目	指標数	加工方法	指標数	項目	指標数	加工方法	指標数
売上	10	月中平残比	29	売上	10	月中平残比	29
原価	5	前月比	21	原価	5	前月比	21
出金投資	1	合計	50	出金投資	1	合計	50
固定費	0			固定費	0		
返済	10			返済	10		
出金その他	5			出金その他	4		
月末残高	12			月末残高	15		
月中平残	7			月中平残	5		
合計	50			合計	50		

### 3. モデル構築方法

預金口座情報モデルの構築に利用する手法は、ランダムフォレスト、正則化ロジスティック回帰モデル(Lasso 回帰・Ridge 回帰)とした。ランダムフォレストは多数の指標を扱いやすく、二値分類の問題においても有効な手法である。また、指標重要度を算出することができることから、預金口座情報における知見の蓄積にも役立つと考えられる。ロジスティック回帰モデルは先行研究においても利用され、既に金融機関の実務においてもスコアリングモデルとして広く導入されており、実務担当にも馴染みがある。ただし、本研究では指標数が多いことから過学習となることを抑制するために正則化項を加えた Lasso 回帰、Ridge 回帰を使用した。デフォルト定義(要管理先基準・破綻懸念先基準)を、変更してもモデル構築方法はすべて同様の手順で行った。

#### 3.1 データセットの分割方法

モデルの構築および検証のためのデータの分割方法について説明を行う。本研究におけるデータは、各企業について基準月をスライドした形で作成されている。このことから、データセット中に同一の企業が複数含まれることとなる(当該期間中にデフォルト先に変化しなかった先については、基準月が 8 か月含まれるため、8 つのデータが存在する)。預金口座情報について、単純に基準月をベースとして分割を行った場合、同一企業の情報を用いてモデルを構築し、検証を行うことになり、適切ではないと思われる。そこでまず顧客 ID 毎に期間中に一度でもデフォルトが発生する先と一度もデフォルトが発生しない先に分割した。その後、それぞれのデータから顧客 ID を無作為に 1:1 に分割し、顧客 ID 毎にモデル構築用データと検証用データとして扱った。つまり同一の企業については全てモデル構築用あるいは検証用の一方に含まれるようにした。なおモデルの評価については上記分割によるモデル構築および検証を 10 回繰り返した結果の平均値を用いる。

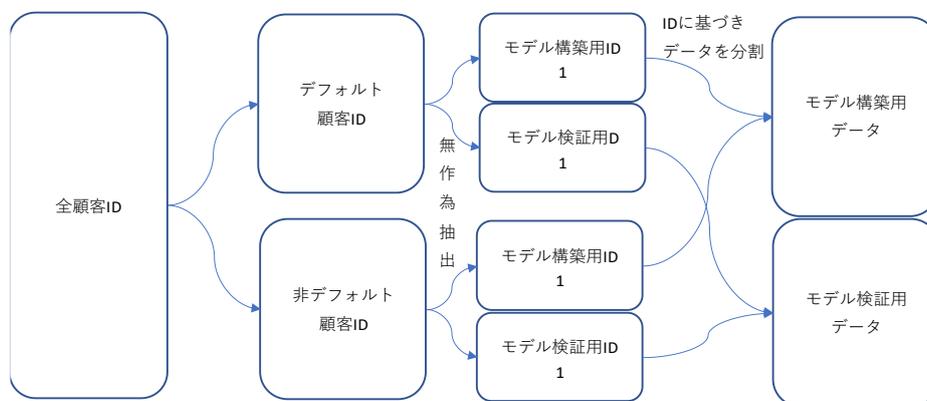


図2 モデル構築用、検証用データ分割方法

## 3.2 モデル評価方法

モデルの評価には AR 値を利用する。AR 値には絶対的な基準値は存在しないものの、過去の研究では、大企業であれば 0.8 程度、中小企業であれば 0.6 程度、小企業では 0.4 程度との結果が報告されている(尾木, 2017)。また、入出金データを用いた三浦他(2019)では 0.7 程度と報告されている。

## 3.3 ランダムフォレスト

ランダムフォレストは弱学習器に決定木を用いたアンサンブル学習である。性質として、入力ベクトルの次元が大きくても高速に学習ができ、また高い汎化性能をもつ。ただし、本研究において扱うデータは、非デフォルト先に対してデフォルト先が 1%程度しか存在しない不均衡なデータである。このようなクラス間でデータ数が偏っている不均衡データに対して単純にランダムフォレストを用いた場合、決定木の各ノードにおいて多数クラスの分類性能を優先した特徴量が最適な特徴量として選択されやすいという特徴がある。したがって本研究では非デフォルト先が多数クラスであることから、非デフォルト先への分類性能を優先した特徴量が選択される可能性がある。そこで、この課題を解決する手法として本研究においては Balanced Random Forest (Chen et al., 2004) を用いることとする。Balanced Random Forest は決定木の学習に利用されるサブセットの作成方法がランダムフォレストと異なる。学習では、まず全訓練データから複数のサブセットを作成し決定木を構築していく。この時サブセットについて、2 クラス間のデータ数が等しくなるように少数クラスのデータ数に合わせてブートストラップサンプリングによって作成する。つまり、多数クラスのデータ数を少数クラスのデータ数に合わせることで、2 クラス間のデータ数が等しいデータセットを作成する。なお、ブートストラップサンプリングとはランダムにデータを抽出するサンプリング手法であり、データの重複や抽出されないデータがあることを許容する。このように用意したサブセットから各決定木を構築する。一般的に決定木の学習では各ノードにおいて全特徴量集合が候補となるが、Balanced Random Forest の学習では、ランダムサンプリングされた特徴量集合が候補となる。この時、サンプリングされる特徴量の数の推奨値は、総数の平方根とされており、本研究でもその数値を利用する。以降本稿では Balanced Random Forest をランダムフォレストと表記する。

なお、ランダムフォレストによるモデル構築を 10 回繰り返した際の指標重要度について、確認したところ全データでの指標重要度と大きな違いは見られなかった。

## 3.4 正則化ロジスティック回帰

スコアリングモデルを構築するにあたって、実務での運用を意識すると精度も重要では

あるが、解釈性や説明力も同様に重要である。財務指標を用いたモデル構築では、定量的な評価や経験則に基づいて有効性の高い指標を重視する手法で変数を選択していくことが多い。しかしながら、預金口座情報においてはデフォルト判別に有効な指標は知見の蓄積が不足している。そこで、定量的な評価として AR 値を単独の指標毎に確認した結果に基づき、閾値以上の値を示した指標のみを利用することとした。ただし、指標によっては単独で計測した AR 値が低位でもデフォルトの判別に有効な指標はあると思われる、ランダムフォレストによる指標重要度から「前月比」に関する指標はその傾向が大きいと思われる。この点、各指標をパーセンタイル値等に基づき離散化し、各区分のデフォルト率に基づきスコア化する手法も考えられ、本データセットについても適用を試みたが、各指標のデフォルトの傾向の解釈が困難であったことから今回は利用を見送った。上記の方法により指標を選択した結果、要管理先基準で 50 指標、破綻懸念先基準で 46 指標となった。含まれる指標を項目・加工方法別に集計した結果を表 8 に示す。単独指標の AR 値でも確認したように、入金項目については、「売上」のみとなった。項目別では要管理先基準では「出金投資」、次いで「返済」、「出金その他」が多く残った。両基準とも加工方法では、「月中平残比」が「前月比」の指標数を上回り、主に「月中平残比」の指標が残った。

表 8 正則化ロジスティック回帰で使用する指標数

要管理先基準				破綻懸念先基準			
項目	指標数	加工方法	指標数	項目	指標数	加工方法	指標数
売上	8	月中平残比	42	売上	9	月中平残比	35
原価	8	前月比	8	原価	8	前月比	11
出金投資	10	合計	50	出金投資	3	合計	46
固定費	1			固定費	2		
返済	9			返済	9		
出金その他	8			出金その他	9		
月末残高	4			月末残高	4		
月中平残	2			月中平残	2		
合計	50			合計	46		

ロジスティック回帰は信用リスク管理の分野で金融機関においても広く利用されているが、本研究では汎化性能を高めることを目的にロジスティック回帰に正則化項を加えた以下の Lasso 回帰および Ridge 回帰を用いた。通常のロジスティック回帰は

$$\log \frac{p}{1-p} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n$$

として定式化される。ここで、 $\log$  は自然対数、 $p$  はデフォルト確率、 $\beta_0$  は切片、 $x_i$  ( $i = 1, 2, \dots, n$ ) は説明変数、 $\beta_i$  ( $i = 1, 2, \dots, n$ ) は係数、 $n$  は採用する説明変数の数を表す。最尤法を用いて対数尤度関数

$$\frac{1}{n} \sum_{i=1}^n [y_i (\beta_0 + \mathbf{x}_i^T \boldsymbol{\beta}) - \log\{1 + \exp(\beta_0 + \mathbf{x}_i^T \boldsymbol{\beta})\}]$$

を最大化するパラメータ  $\beta_0$ ,  $\beta$  を求める。Lasso 回帰においてはこの対数尤度関数に回帰係数の絶対値の和である正則化項を加えた正則化対数尤度関数

$$\frac{1}{n} \sum_{i=1}^n [y_i(\beta_0 + \mathbf{x}_i^T \boldsymbol{\beta}) - \log\{1 + \exp(\beta_0 + \mathbf{x}_i^T \boldsymbol{\beta})\}] - \lambda \|\boldsymbol{\beta}\|_1$$

を最大化することによって得られる。ここで、 $\lambda$  は正の値を取る正則化パラメータである。 $\lambda$  の値を適切に設定することにより、回帰係数のいくつかの値を 0 に推定することができ、変数選択の効果があるモデルとなる。

一方、Ridge 回帰は Lasso 回帰における正則化項に係数の二乗和を用いたものとなる。Ridge 回帰では係数が 0 に推定されることはなく、変数選択の効果はないものの、係数の大きさに制限を加えることで、汎化性能を高めることができる。

Lasso 回帰および Ridge 回帰においては正則化パラメータである  $\lambda$  を選択することが必要になる。この点については、クロスバリデーションによって平均二乗誤差が最小化するように  $\lambda$  のチューニングを行った。

### 3.4.1 Lasso 回帰

Lasso 回帰についてモデル構築を 10 回繰り返した結果、選択された指標について確認する。要管理先基準では平均 31 個、破綻懸念先基準では平均 27 個の指標が選択された。10 回中 8 回以上モデルで選択された指標を項目・加工方法ごとに集計した結果を表 9 に示す。要管理先基準、破綻懸念先基準どちらにおいても項目では「返済」が最も選択されていることが分かる。なお、これらの係数の符号を確認したところ「返済」の月中平残比指標では全て「正」であったことから月中平残に対する返済金額が大きいほどデフォルトしやすいモデルとなっており、返済の資金繰りが苦しい企業がデフォルトしやすいという実感覚とも合う。また、「出金投資」の月中平残比指標では符号が「負」となっており、投資信託等の運用商品の購入が行われるような企業は資金繰りに余裕があると考えられ、こちらも実感覚に沿う結果と言える。

表 9 lasso 回帰による選択指標(預金口座情報モデル)

要管理先基準				破綻懸念先基準			
項目	指標数	加工方法	指標数	項目	指標数	加工方法	指標数
売上	2	月中平残比	13	売上	1	月中平残比	10
原価	1	前月比	4	原価	2	前月比	4
出金投資	2	合計	17	出金投資	1	合計	14
固定費	1			固定費	1		
返済	6			返済	5		
出金その他	2			出金その他	1		
月末残高	1			月末残高	2		
月中平残	2			月中平残	1		
合計	17			合計	14		

### 3.4.2 Ridge 回帰

Ridge 回帰も Lasso 回帰と同様にモデルを構築した。Ridge 回帰では推計した係数の結果に基づいて各指標の寄与度について確認する。寄与度とはスコアリングモデルのスコア全体に占める説明変数ごとのいわば「配点」を表現するための考え方の一つである(尾藤, 2019)。寄与度は、モデルに使用した指標ごとの最大値と最小値の差に係数の絶対値を乗じた値を、モデル全体の合計で除することで算出される。つまりモデル全体の評点を 100 点と換算した際の指標毎の配点であり、寄与度が大きければ大きいほど、その指標の大小によってスコアに大きな差がつくことを意味している。この考え方はスコアと指標の関係を分かりやすく伝えることに向いており、審査部門や営業部門にスコアリングモデルによる結果を説明する際などに広く金融機関で用いられている。項目・加工方法(月中平残比・前月比)ごとの寄与度を合計した結果を表 10 に示す。

要管理先基準については「返済」の指標の寄与度が最も大きく、「出金投資」、「出金その他」と続いた。この結果は単独指標 AR 値や Lasso 回帰による指標選択の結果とも整合的であると思われる。一方で、破綻懸念先基準については「返済」、「出金その他」が上位 2 項目となっている点は同様であるが、「出金投資」については寄与度が大きく低下していた。加工方法については両基準ともに「残高比」が「前月比」よりも大きな寄与度となったが、破綻懸念先基準では「前月比」の寄与度が要管理先基準と比較して大きくなっていった。この点、破綻懸念先では預金口座の推移が安定していないものと考えられる。

表 10 Ridge 回帰寄与度(預金口座情報モデル)

要管理先基準				破綻懸念先基準			
項目	寄与度	加工方法	寄与度	項目	寄与度	加工方法	寄与度
売上	10.6	残高比	74.5	売上	14.1	残高比	60.7
融資	0.0	前月比	25.5	融資	0.0	前月比	39.3
入金投資	0.0	合計	100	入金投資	0.0	合計	100
入金その他	0.0			入金その他	0.0		
原価	9.1			原価	11.2		
出金投資	19.4			出金投資	6.7		
変動費	0.0			変動費	0.0		
固定費	4.0			固定費	7.0		
返済	24.0			返済	20.3		
出金その他	14.6			出金その他	17.1		
月末残高	9.7			月末残高	13.3		
月中平残	8.6			月中平残	10.2		
合計	100			合計	100		

## 4. モデル構築結果

### 4.1 預金口座情報モデル

前節で述べた手法に基づいて構築した各モデルについて検証用データを利用して算出したAR値(平均値)および標準偏差を表11に示す。なお、入出金データを項目に分類したことの有効性を確認するために、ランダムフォレストおよびRidge回帰においては細分化した入出金項目を用いたモデルだけではなく、月次の入出金区分ごとに合計した「入金合計」、「出金合計」を項目として作成した指標を用いたモデルを追加で構築している。

表11 預金口座情報モデルAR値

デフォルト基準	モデル	AR値(平均)	標準偏差
要管理	ランダムフォレスト	0.452	0.022
	Lasso回帰	0.396	0.034
	Ridge回帰	0.406	0.035
	ランダムフォレスト(入金合計・出金合計)	0.366	0.025
	Ridge(入金合計・出金合計)	0.351	0.063
破綻懸念	ランダムフォレスト	0.525	0.034
	Lasso回帰	0.464	0.022
	Ridge回帰	0.476	0.024
	ランダムフォレスト(入金合計・出金合計)	0.471	0.043
	Ridge回帰(入金合計・出金合計)	0.459	0.064

預金口座情報モデルの評価については以下の通りである。

- ・AR値についてはどちらのデフォルト基準においてもランダムフォレスト⇒Ridge回帰⇒Lasso回帰の順となり、ランダムフォレストが最も優れた結果となった。より多くの変数を取り入れられ、非線形な判別が可能な手法がデフォルト判別においても有効であったと考えられる。
- ・Lasso回帰とRidge回帰ではRidge回帰の方が優位となったものの、その差は0.01程度と僅差であり、指標数を削減しても汎化性能を維持できる可能性が考えられる。
- ・入金合計・出金合計のみを使用したモデルについてはランダムフォレスト、Ridge回帰の双方で入出金を細分化したモデルと比べ、AR値が低水準となっており、入出金データについて項目に分類することは、モデルの性能を向上させることに寄与していると思われる。一方で、破綻懸念先基準では、入金合計・出金合計のみを利用したモデルにおいても性能の劣化は小さかった。ただし、AR値の標準偏差が大きくなっており、項目に分類することはモデルの汎用性を向上させることに有効であると考えられる。
- ・デフォルト基準については、破綻懸念先基準が要管理先基準と比較して全てのモデルで良好な結果を示しており、破綻懸念先基準のデフォルトを予測することに預金口座情報はより有効であると考えられる。このことは、破綻懸念先以下は実態の業績が困窮していることから特徴が表れやすくなっていると思われる。一方で要管理先基準では、金融機関の管理上早期のランクダウンも含まれることから、デフォルト先であっ

ても預金口座の動きには業況の変化が表れていないデータが含まれ、予測が困難であった可能性が考えられる。ただし、要管理先基準と破綻懸念先基準では構築用と検証用のデータ分割におけるサンプリングが異なることには留意が必要である。

- ・AR 値については一般的に中小企業を対象とした場合には 0.6 程度あれば有効性が高いとされており、その水準には一步及ばない結果ではあるものの、破綻懸念先基準においては実用に耐える水準である。

## 4.2 金融機関格付との相関分析

次に各預金口座情報モデルにより算出されたスコアについて、金融機関格付との相関関係について確認する。ここで利用する金融機関格付について簡単に説明を行っておく。金融機関では取引先に対する格付について以下のような手順で付与している。まず、決算書等から得られる財務情報を用いて、スコアリングモデルによって定量的なスコア付けを行う。次に業界動向や延滞、コンプライアンス事象等の決算書上に表れない定性的な情報について一定のルールに基づき調整を行う。最後に審査担当者が個別の企業の事情を考慮して最終的な格付(以下、内部格付)を付与することになる。今回の分析には内部格付を利用する。つまり、財務情報だけではなく定性的な情報や審査担当者の目線も含めた最終的な企業の評価になる。

内部格付は対象先について格付区分を数値に変換し、1 が最優良先で数字が大きいほど評価が悪くなりデフォルト率が高くなることを想定される指標とした。この指標と各預金口座情報モデルに基づくスコアの相関係数を算出した結果が以下の表 12 である。どのモデルについても相関係数が概ね 0.2~0.3 程度となっていることから、預金口座モデルと内部格付の相関関係があまり強くないことが分かる。このことは預金口座モデルが従来の格付モデルとは異なる切り口で企業のデフォルト予測を行っていることを示唆しており、内部格付においては本研究で利用しているような預金口座情報は十分に取り入れられていないと思われる。そこで預金口座情報に加え、内部格付指標を組み合わせた統合モデルの構築を行い、各モデルの精度を検証する。

表 12 預金口座情報モデルスコアと内部格付指標の相関係数

デフォルト基準	モデル種類	相関係数
要管理先	ランダムフォレスト	0.264
	Lasso回帰	0.200
	Ridge回帰	0.207
破綻懸念先	ランダムフォレスト	0.277
	Lasso回帰	0.235
	Ridge回帰	0.240

### 4.3 統合モデル

統合モデルについては、預金口座情報モデルで使用した指標に金融機関格付を数値に変換して指標に加えたデータを作成する。その他のモデルの構築、検証方法については預金口座情報モデルと同様の手法で行った。

統合モデルによる AR 値を表 13 に示す。

表 13 統合モデル AR 値

デフォルト基準	モデル	AR値(平均)	標準偏差	改善幅
要管理	ランダムフォレスト	0.593	0.017	+0.141
	Lasso回帰	0.682	0.031	+0.285
	Ridge回帰	0.679	0.026	+0.274
	ランダムフォレスト(入金合計・出金合計)	0.601	0.029	+0.235
	Ridge(入金合計・出金合計)	0.665	0.031	+0.315
破綻懸念	ランダムフォレスト	0.658	0.036	+0.133
	Lasso回帰	0.747	0.024	+0.283
	Ridge回帰	0.751	0.020	+0.275
	ランダムフォレスト(入金合計・出金合計)	0.675	0.045	+0.204
	Ridge回帰(入金合計・出金合計)	0.745	0.032	+0.286

統合モデルの評価は以下の通りである。

- ・内部格付を加えた結果、すべてのモデルについて結果が大幅に改善したものの、ランダムフォレストについては結果の改善幅が小さかった。また、ランダムフォレストについては内部格付の単独 AR 値よりも低下した結果となった。これはデータセットの分割やサンプリングの結果によっては、本来明確に序列性がある指標である内部格付において、一部序列性に逆転が起き、非線形的な判別を行っていることが影響している可能性が考えられる。この点に関しては今後サンプルサイズを充実させることで解決できる問題であると思われる。なお、ランダムフォレストによる指標重要度については、内部格付が最も高かった。
- ・Lasso 回帰および Ridge 回帰については、預金口座情報モデルよりも大きく改善した結果となった。ランダムフォレストで見られたような一部の内部格付の序列性が逆転していても、内部格付が悪化するほどデフォルトしやすい傾向にあったことから、線形モデルにおいてはランダムフォレストのような影響は見られなかったと思われる。内部格付のみの AR 値と比較しても 0.03~0.05 程度の改善が見られ、預金口座情報を加えることで現行の内部格付の精度向上につながり、信用リスク管理の高度化を図れることが示された。
- ・Lasso 回帰について、選択された指標を確認したところ、平均指標数について要管理先基準で 28 個、破綻懸念先基準で 29 個となり、預金口座情報モデルと比較してわずかではあるが減少した。

- ・両基準とも Lasso 回帰で 10 回中 8 回以上選択された指標(表 14)について確認すると、「返済」指標が多く選択されており、この点は預金口座情報モデルと同様の傾向であった。一方で加工方法別に確認すると、「月中平残比」の指標が選択されることは少なくなった。この要因について、預金残高を踏まえた入出金については内部格付を付与する審査で一定程度考慮されている可能性が有ると考えられる。
- ・Ridge 回帰の寄与度(表 15)については「内部格付」指標が最大となり、内部格付の寄与度は要管理先基準、破綻懸念先基準どちらも同程度であった。
- ・加工方法では預金口座情報モデルと比較したときに「月中平残比」の寄与度が大きく低下しており、このことから預金残高を踏まえた情報が内部格付に反映されていると考えられる。

表 14 Lasso 回帰による選択指標(統合モデル)

要管理先基準				破綻懸念先基準			
項目	指標数	加工方法	指標数	項目	指標数	加工方法	指標数
内部格付	1	内部格付	1	内部格付	1	内部格付	1
売上	1	月中平残比	6	売上	2	月中平残比	9
原価	0	前月比	4	原価	1	前月比	6
出金投資	3	合計	11	出金投資	1	合計	16
固定費	0			固定費	1		
返済	3			返済	6		
出金その他	1			出金その他	1		
月末残高	0			月末残高	2		
月中平残	2			月中平残	1		
合計	11			合計	16		

表 15 Ridge 回帰による寄与度(統合モデル)

要管理先基準				破綻懸念先基準			
項目	寄与度	加工方法	寄与度	項目	寄与度	加工方法	寄与度
内部格付	28.4	内部格付	28.4	内部格付	29.5	内部格付	29.5
売上	9.1	残高比	49.5	売上	9.5	残高比	40.3
融資	0.0	前月比	22.0	融資	0.0	前月比	30.1
入金投資	0.0	合計	100	入金投資	0.0	合計	100
入金その他	0.0			入金その他	0.0		
原価	6.3			原価	6.8		
出金投資	15.2			出金投資	6.2		
変動費	0.0			変動費	0.0		
固定費	2.8			固定費	5.6		
返済	15.5			返済	14.2		
出金その他	9.0			出金その他	13.3		
月末残高	6.7			月末残高	7.5		
月中平残	6.9			月中平残	7.3		
合計	100			合計	100		

## 5. 結論と今後の課題

本節では、本研究の分析結果をまとめ、そこから得られた知見および今後の検討すべき課

題について述べる。

## 5.1 結論

本研究においては、金融機関における企業デフォルト予測において、預金口座情報を用いたモデルを構築し、一定の精度が得られることが確認された。また、預金口座情報によるスコアと銀行の内部格付の相関関係は強くなく、異なる目線で企業を評価していると分かる。加えて、預金口座情報と内部格付を組み合わせた統合モデルでは、正則化ロジスティック回帰を用いたモデルにおいて、内部格付単独の AR 値を改善できたことから、預金口座情報を利用することは信用リスク管理の精緻化に有効であることが示された。モデルの精度については改善の余地があると思われるものの、預金口座情報のみを用いていることから売上高等決算書に基づく情報を取得できていない企業にも利用することが可能である。また、金額そのものの指標を含まないことから、規模による影響を一定排除できていると考えられ、規模が小さな中小企業を対象とするスコアリングモデルに適していると思われる。ただし、規模と相関が強い可能性がある指標(例えば、「月中平残比の標準偏差」の指標は規模が小さく月中平残が小さい企業ほど大きくなりやすいと考えられる)が含まれる可能性もあり、「売上高」や「総資産」といった規模を表す指標との相関を確認する必要はある。

モデル構築方法としては、要管理先基準、破綻懸念先基準のいずれにおいてもランダムフォレストが正則化ロジスティック回帰を上回る結果となっており、デフォルト判別において非線形モデルの利用の有効性が見られた。しかしながら、特に破綻懸念先基準においては正則化ロジスティック回帰モデルでも AR 値が高いモデルとなっており、モデルの理解、説明のしやすさ等を考慮すると、こちらを選択する判断もできる。

実務での活用については、スコアリングモデルとして内部格付制度に利用するためには、金融庁等が定める厳密な説明責任が求められることとなる。現状ではその条件を満たすことはできておらず、現行のスコアリングモデルと同様に利用することは難しいが、内部管理における取引先の業況変化等に対するアラームや格付を付与するにあたってのサポートとして利用するような形が考えられる。特に期中においては担当者が訪問等を通じて情報を収集する必要が無く、また、経験やスキルに依存することなく一定の基準を設けられ、信用リスク管理を高度化できると思われる。金融機関における内部格付と預金口座情報モデルの相関関係は弱いことから、内部格付が低評価であっても、預金口座情報モデルが高評価の企業については融資を拡大することによる収益機会の獲得、あるいは内部格付が高評価で預金口座情報モデルが低評価の企業については担当者の早期のモニタリングによる実情把握や適切な金利プライシングを行うことによる信用リスク管理への活用も考えられる。

## 5.2 今後の課題

最後に預金口座情報を用いたモデルを構築するにあたって、今後検討すべき課題を挙げておく。

### ①景気情勢の変化

近年のデフォルト率は「RDB 企業デフォルト率」(日本リスク・データ・バンク株式会社)によると1%前後で推移しており、また、本研究では単一の金融機関から取得したデータを用いてモデルを構築していること、加えて、取得できた入出金データの期間が短期間であったことからデフォルト先の数に限られている。過去の景気後退期、例えばリーマンショックが発生した2008年前後においてはデフォルト率が3%前後の水準であり、景気情勢が変化した際のモデルの頑健性や精度については検証が必要である。

### ②預金口座情報データの蓄積

スコアリングモデルを構築するには十分なサンプルサイズが必要となる。預金口座情報は、金融機関において自動的に収集されているものの、容易に取得・使用が可能なデータ数は直近数年であることも多く使用可能なデータの蓄積が課題となる。また、デフォルト企業についても単独で十分なサンプルサイズを確保することは難しい。この点、決算情報等と紐づいたデフォルト情報であれば一般社団法人 CRD 協会等を通じて複数の金融機関のデータ蓄積が進んでいるが、預金口座情報を含めたデータについては今後蓄積が必要である。

加えて、預金口座情報を共有してモデル構築を行うにあたっては金融機関によってシステムが異なることも課題となる。単純な預金残高や入出金合計であれば金融機関によって集計が違ふといったことは無いと考えられる。しかしながら、入金データについて入出金合計等の粒度では項目に細分化したモデルと比較して性能が劣化する結果であり、十分ではない可能性が有る。また、本研究において用いた摘要コードによる入出金を利用するのであれば、金融機関によって、システム上保有する摘要コードが一致しないケースが想定され、どのように分類するかも課題として考えられる。

### ③対象企業の区分

財務情報を用いたスコアリングモデルでは、業種等を切り口として複数のモデルを構築するケースも多い。本研究においては業種等の対象先を細分化する区分の検証を行うことはできなかった。預金口座情報でも業種によって入出金の傾向に特徴が見られると思われる。データの蓄積が進めば検討すべきである。しかしながら、預金口座情報を利用したモデルを構築するにあたっては業種によって区分する方法以外にも取引状況を考慮した区分が考えられる。例えば、大型の受注が発生するような企業なのか、定期的な入金が発生する企業なのかといった区分が考えられる。

### ④入出金項目

本研究において入出金データを項目に分類し、集計することはモデルの性能向上に有効であることが確認された。しかしながら、本研究における項目は実務経験から想定される性質に基づいて設定したものの、項目の設定方法が適切かどうかは不明である。少なくとも、

モデル構築において単独指標のAR値やランダムフォレストによる指標重要度、Lasso回帰による変数選択において確認できた有効性の高い項目については偏りが見られ、特に入金区分においては売上以外の項目が選択されなかったことから、項目の作成方法については検討の余地はある。

#### ⑤複数口座保有企業

預金口座情報を扱うにあたって大きな課題となるのは、企業が保有する金融機関口座は一つとは限らないことである。複数の金融機関で取引をしている企業であれば、一つの金融機関が預金口座情報から得られる情報はその企業活動の一部であり、断片的な情報となる。その点決算書は速報性、正確性においては課題が残るものの、企業情報を網羅的に示したものであり、情報が不足することはない。「企業アンケート調査の結果」(金融庁, 2020)によると取引金融機関の数が「1行」と回答した企業は18%程度にとどまる。本研究においては、預金口座残高を用いて入出金金額を基準化することで、シェアの影響の緩和を図ったものの、実務で活用するにあたっては、メイン口座であるか否か、あるいは口座シェアについて考慮する手法を検討する必要があると思われる。なお三浦他(2019)においては、「(入出金情報から計算される)直近1年間の入金売上合計が、損益計算書上の売上高の30%以上を占める先」としてメイン口座先と定義し、非メイン先との差異について検証を行っており、メイン先については非メイン先と比べ精度が高いとしている。

## 追加検証

### 1. データセット作成方法の変更

本文中においてはモデル構築用、検証用データについて顧客 ID を基準として分割を行った。ここでは時間軸をベースとしてデータセットを分割した結果を確認する。2019年6月以前のデータをモデル構築用データ、2019年7月以降のデータを検証用データとしてAR値を算出した結果を示す。表中の差は本文中における各モデルの平均AR値との差である。

表 16 基準月ベースのデータセット分割による AR 値(預金口座情報モデル)

デフォルト基準	モデル	AR値	差
要管理	ランダムフォレスト	0.587	+0.136
	Lasso回帰	0.453	+0.057
	Ridge回帰	0.451	+0.045
破綻懸念	ランダムフォレスト	0.644	+0.119
	Lasso回帰	0.482	+0.018
	Ridge回帰	0.489	+0.013

表 17 基準月ベースのデータセット分割による AR 値(統合モデル)

デフォルト基準	モデル	AR値	差
要管理	ランダムフォレスト	0.706	+0.113
	Lasso回帰	0.718	+0.037
	Ridge回帰	0.709	+0.030
破綻懸念	ランダムフォレスト	0.762	+0.104
	Lasso回帰	0.771	+0.024
	Ridge回帰	0.763	+0.012

預金口座情報モデルについては破綻懸念基準における正則化ロジスティック回帰モデルは影響が小さいものの、全てのモデルでAR値が改善する。特にランダムフォレストモデルでAR値が大きく改善した結果となった。基準月をベースとした分割方法では本研究におけるデータセットに同一企業が含まれることから、精度の高いモデルが構築されてしまう可能性が懸念され、サンプリング方法を慎重に行う必要がある。

また、統合モデルにおいて、ランダムフォレストも内部格付単独のAR値を上回る結果となっており、基準月による分割であれば内部格付によるデフォルトの序列性が大きく崩れることがなかったことから、精度の向上につながったと考えられる。

## 2. デフォルト観測期間の短期化

本文中ではデフォルト観測期間を12か月としたが、より短期とした際のデフォルト予測性能の変化について確認をするために、デフォルト観測期間について短期間に変更した際にモデルの精度に変化があるかを確認する。以下ではデフォルト観測期間を6か月に短縮した結果を確認する。モデルの構築方法等については本文中と同様の手法をとっている。表中の差はデフォルト観測期間12か月のAR値との差である。デフォルト観測期間を短縮した結果、僅差ではあるものの全てのモデルにおいてAR値は良好な結果となった。この結果は、直感とも整合的である。ロジスティック回帰モデルにおいて改善が大きく、デフォルト観測期間が短ければ少ない情報でも予測が可能であると思われる。

表 18 デフォルト観測期間 6 か月データセット

デフォルト基準	対象先数	与デフォルト先数	デフォルト率
要管理先	129,857	752	0.58%
破綻懸念先	129,958	540	0.42%

表 19 デフォルト観測期間 6 か月 AR 値

デフォルト基準	モデル	AR値	差
要管理	ランダムフォレスト	0.468	+0.017
	Lasso回帰	0.423	+0.027
	Ridge回帰	0.429	+0.023
破綻懸念	ランダムフォレスト	0.535	+0.010
	Lasso回帰	0.484	+0.020
	Ridge回帰	0.504	+0.027

## 謝辞

本論文の執筆にあたり，多くの方々にご支援いただきました。主指導教員である田中琢真准教授には，研究手法から，論文執筆まで多くのご指導をいただき感謝の意を表します。

今回，新設された滋賀大学データサイエンス研究科では今まで触れたことのない多くの知識に触れ，貴重な経験をさせていただきました。滋賀大学の先生方からは熱心なご指導をいただいたこと，大学院の同期の皆様からは良い刺激を受けましたことに心からお礼を申し上げます。また，企業からの派遣という形式で実現した本研究につきまして，滋賀銀行の寛大な対応に感謝申し上げます。職場の上司である久保田真也専務取締役，大野恭永監査役(前常務取締役)，下辻篤理事(前経営管理部長)，木澤敬人経営管理部長には多大なるご配慮と温かいご支援をいただきました。また，本研究に勤しむ時間を与えて下さった経営管理部の皆様からはたくさんのお心遣いをいただきました。心から感謝の意を申し上げます。

## 参考文献

Altman, E. I. (1968), "Financial ratios, discriminant analysis and the prediction of corporate bankruptcy." *Journal of Finance* 23, 589-609.

Chen, C., Liaw, A. and Breiman, L. (2004) "Using random forest to learn imbalanced data." University of California, Berkeley 110: 1-12

Crook, J. and Banasik, J. (2004) "Does reject inference really improve the performance of application scoring models?" *Journal of Banking & Finance* 28 (2004) 857-874

Yao, J., Chapira, M. L. and Margaryan, M. (2017) "Checking account activity and credit default risk of enterprises: An application of statistical learning methods." arXiv:1707.00757v1.

尾木研三 (2017) 「スコアリングモデルの基礎知識 中小企業融資における見方・使い方」, 金融財政事情研究会.

上武治紀・吉田博哉・枇々木規雄(2020)「銀行口座の入出金情報に基づく個人の行動特性を考慮したカードローンのデフォルト分析とモデル化」*日本統計学会誌* 第 49 卷, 第 2 号, 2020 年 3 月 217-240

川野秀一・松井秀俊・廣瀬慧(2018)「スパース推定法による統計的モデリング」, 共立出版

金融庁(2003)「リレーションシップバンキングの機能強化に関するアクションプログラム」<https://www.fsa.go.jp/news/newsj/14/ginkou/f-20030328-2/01.pdf> (2021 年 1 月 11 日)

金融庁(2016)「平成 28 事務年度 金融行政方針」<https://www.fsa.go.jp/news/28/20161021-3/02.pdf> (2021 年 1 月 11 日)

金融庁(2020)「企業アンケート調査の結果」<https://www.fsa.go.jp/policy/chuukai/shiryou/questionnaire/201014/01.pdf> (2021 年 1 月 11 日)

金融庁「金融検査マニュアル(預金等受入金融機関に係る検査マニュアル)」<https://www.fsa.go.jp/manual/manualj/yokin.pdf> (2021 年 1 月 12 日)

中小企業庁(2015)「平成 26 年度 中小企業における会計の実態調査事業 報告書」  
[https://warp.da.ndl.go.jp/info:ndljp/pid/11473025/www.meti.go.jp/meti\\_lib/report/2015fy/000633.pdf](https://warp.da.ndl.go.jp/info:ndljp/pid/11473025/www.meti.go.jp/meti_lib/report/2015fy/000633.pdf) (2021 年 1 月 11 日)

中小企業庁(2020)「2020 年版中小企業白書 小規模企業白書」

中小企業庁「倒産の状況」<https://www.chusho.meti.go.jp/koukai/chousa/tousan/index.htm>  
(2021 年 1 月 11 日)

独立行政法人中小企業基盤整備機構(2018)「経営者保証ガイドラインアンケート」  
[https://www.smrj.go.jp/doc/research\\_case/keieisha\\_question2017.pdf](https://www.smrj.go.jp/doc/research_case/keieisha_question2017.pdf) (2021 年 1 月 11 日)

日本銀行金融機構局金融高度化センター (2019)「AI 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」(2019 年 2 月 18 日開催)。  
[https://www.boj.or.jp/finsys/c\\_aft/data/aft190902c.pdf](https://www.boj.or.jp/finsys/c_aft/data/aft190902c.pdf) (2021 年 1 月 11 日)

日本リスク・データ・バンク株式会社 「RDB 企業デフォルト率」  
<https://www.riskdatabank.co.jp/rdb/top/> (2021 年 1 月 11 日)

根本直子・吉野直行・大久保豊・稲葉大明・柳澤健太郎 (2019)「銀行口座動態情報を活用した中小企業の信用リスク分析」, 『現代ファイナンス』 No. 40, pp. 49-71

尾藤剛 (2019)「究解 信用リスク管理」大久保豊監修,金融財政事情研究会.

藤井 真理子・竹本 遼太(2010)「中小企業のデフォルトリスクとその期間構造：大規模財務データによる実証分析」金融庁金融研究研修センター ディスカッションペーパー DP2009-12(2010 年 3 月)

平田英明(2005)「わが国中堅・中小企業金融の新しい展開」法政大学経営学会 経営志林 第 41 巻 2 号 2005 年 7 月

三浦 翔・井實 康幸・竹川 正浩(2019)「入出金情報を用いた信用リスク評価－機械学習による実証分析－」,日本銀行ワーキングペーパーシリーズ

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比較と考察」, 金融庁金融研究研修センター ディスカッションペーパー

<https://www.fsa.go.jp/frtc/seika/discussion/2003/20031031.pdf> (2021年1月11日)

山下智志・三浦翔(2011)「信用リスクモデルの予測精度: AR 値と評価指標」朝倉書店