

高粒度データを活用した 本邦金融システムに関する分析事例

—金融行政の高度化に向けて—

金融庁総合政策局リスク分析総括課 マクロ・データ分析監理官

齊藤 剛

同マクロ・データ分析監理官室 ブルーデンス企画調整官

梶原 耕太郎

同マクロ・データ分析監理官室 課長補佐

川井 大輔

同マクロ・データ分析監理官室 課長補佐

松本 光右

同マクロ・データ分析監理官室 係長

関口 宥人

1 はじめに

金融庁（以下「当庁」という。）では、金融行政の高度化を図るため、データ基盤の充実・強化及び分析力の向上に向けたさまざまな取組みを進めている。

データ基盤については、直近数年での大きな進展に、新しいデータ収集・管理の枠組みとして日本銀行と構築した共同データプラットフォーム（以下「共同DP」という。）のもとでの、貸出明細等の高粒度データの収集がある。本取組みは、より質の高いモニタリングの実施と金融機関の負担軽減を図る観点から進めているものであり、これまでの進展としては、共同DPを通じた高粒度データ収集を2023年9月期より段階的に開始し、2025年3月期からは本格的に開始している。共同DPを通じて収集される高粒度データは、銀行が実行した各貸出しの明細情報等を含んでおり、当庁において金融機関の貸出しに関してよりきめ細かく

多面的な分析・実態把握を行うことを可能とするものである。

当庁ではデータ分析力の向上のため、共同DPで収集された高粒度データをそれ以外のデータと併せて活用し、マクロの視点からの分析や、AIや機械学習等の新たな技術を取り入れた分析を試行している。そのうち、一部の分析結果は、「金融庁データ分析事例集—FSA Analytical Notes—」（以下「FAN」という。）として公表している。当庁ではこのほか、データ分析に関する講演、庁内外の勉強会、意見交換会等のさまざまな機会に分析の目的、手法、結果についてフィードバックを求めることなどを通じ、知見をいっそう深め、さらなるデータ分析の高度化に努めている。

本稿では、こうした取組みについて、FANに収録された最近の分析を中心に紹介する。以下、各分析の内容を概説する。

まず、「地域銀行の信用リスク管理態勢の実態把握に向けた分析」¹では、地域銀行²の貸出明細データ³を用い、債務者区分⁴、単独貸出・共通貸

1 FSA Analytical Notes (2025.6) vol.2「地域銀行の信用リスク管理態勢の実態把握に向けた分析」。

2 本稿では、特に断らない限り、「地方銀行」は埼玉りそな銀行及び全国地方銀行協会加盟行、「第二地方銀行」は第二地方銀行協会加盟行、「地域銀行」は地方銀行及び第二地方銀行を指す。

3 共同DPを通じて収集する高粒度データ等のうち、銀行が実行した貸出しの明細に関するデータ。

出の別や越境貸出に該当する場合といった観点から、貸出債権の保全状況にどのような特徴が見られるかについて分析している。加えて、債務者区分遷移のパターン別に、企業の財務情報が債務者区分の遷移に与える影響を確認するため、機械学習の手法を用いて企業の財務情報の要素別に債務者区分の遷移の予測の精度の比較を行っている。

次に紹介する「地方銀行の貸出明細データ等とマクロ経済指標を用いた信用リスクに関する予兆分析の試行」⁵では、地方銀行の法人向け貸出明細と国内外のマクロ経済指標を結合し、債務者区分の下方遷移の予測を目的とした機械学習モデルを構築して、その精度の検証と説明可能性分析を行っている。

さらに、「地方銀行の住宅ローンのデフォルト状況に関する分析」⁶では、地方銀行が保有する住宅ローン債権について、本店所在地の地域、実行年度、実行金額等の性質ごとに、デフォルト率の水準や差異を実証的に把握している。

最後に、上記分析に関連して行っている不動産業向け貸出及び住宅ローン（以下「不動産関連貸出」という。）に関する分析について紹介する。本分析は、足もとにおける不動産価格の高騰や不動産業向け貸出残高の積み上がりを受けて、不動産関連貸出におけるリスク動向について実態把握を進めるべく、FANに掲載した分析に用いた手法や、それらの分析を通じて得られた知見をもとに実施したものである。

各分析の具体的な内容については、次章以降で解説するが、本稿では、紙幅の都合上、概要を紹

介するにとどめているので、詳細に関心がある場合は各FANをご覧ください。また、一部図表については、カラー版をFANに掲載しており、関心のある場合、各FANもご覧ください。なお、本稿中出所を明記していない図表は、いずれもそれぞれに対応するFANから引用している。

2 地域銀行の信用リスク管理態勢の実態把握に向けた分析

(1) 目的・概要

本章では、地域銀行の貸出明細データを用いて行った、保全状況に関する分析及び債務者区分の遷移予測モデルの検証について述べる。本分析は、金融機関の信用リスク管理態勢に関して定量的な分析を試みたものであり、2025年1月に別途公表したFANである「共通貸出先に対する債務者区分の付与状況に関する分析」⁷の内容をさらに深掘りしたものである。本分析では、地域銀行の貸出明細データを用いて、①保全状況に関する分析及び②債務者区分の遷移予測モデルの検証を行った。前者の分析では、単独共通別⁸（単独貸出先か共通貸出先か）や越境別⁹（圏内向けか圏外向けか）などの観点から保全状況の実態把握を行い、後者の分析では、債務者区分の決定に財務情報が影響している程度が債務者区分ごとに異なる可能性を確認する観点から機械学習の手法を用いて財務情報のみで複数の債務者区分遷移の予測モデルを構築し、精度比較を行った。なお、前者の保全

4 各金融機関が貸出先の財務状況等を勘案し信用リスクに応じて付与する区分。貸出明細データでは、債務者区分を「正常先、その他要注意先、要管理先、破綻懸念先、実質破綻先、破綻先」の6区分で表記しており、本稿では、特に断らない限り、これにない表記する。

5 FSA Analytical Notes (2025.6) vol.3「地方銀行の貸出明細データ等とマクロ経済指標を用いた信用リスクに関する予兆分析の試行」。

6 FSA Analytical Notes (2025.10)「地方銀行の住宅ローンのデフォルト状況に関する分析」。

7 FSA Analytical Notes (2025.1) vol.2「共通貸出先に対する債務者区分の付与状況に関する分析」。

8 「単独貸出先」とは同一の銀行が貸出しを行っている債務者を指し、「共通貸出先」とは複数銀行が貸出しを行っている債務者を指す。当該分類は地域銀行及び大手行（みずほ銀行（みずほ信託銀行を含む。）、三菱UFJ銀行、三井住友銀行、三井住友信託銀行、りそな銀行、あおぞら銀行、SBI新生銀行）を対象として判断しており、信用金庫等の業態は考慮されていない。

9 本稿では、特に断らない限り、「越境貸出」とは、本店所在地が属する都道府県以外への貸出しを指す。なお、各行によって営業基盤とする区域は異なっていることから、実態としては、本店所在地外の都道府県への貸出しをもって越境貸出とはいえない場合もある点には留意が必要である。

状況に関する分析は、保全状況が貸出先企業の規模・特性や銀行の与信方針等によって異なることを前提とした実態把握であり、保全状況の適切性等を論じることを意図したものではない点に留意が必要である。

(2) 保全状況に関する分析

本分析では、貸出明細データの2024年3月末基準日時点の地方公共団体を除く法人貸出先のうち、保全に関する情報が把握可能な先を検証対象とした。当該対象は地域銀行の地方公共団体を除く法人貸出残高全体の約5割を占めている¹⁰。

【図表1】は、当該データについて、債務者区分別、単独共通別、越境別の保全率¹¹の状況を示したものである。これによると、破綻懸念先以下¹²は総じて高い保全率であるものの、正常先及び要注先においては、単独貸出先・圏内向け、単独貸出先・圏外向け、共通貸出先・圏内向け、共通貸出先・圏外向けの順に保全率が低くなる傾向が確認された。このような傾向が見られる理由としては、複数借入れであることから単独貸出先よりも共通貸出先の方が保全に係る交渉を地域銀行が行うことが困難となる可能性や、圏内よりも圏外の方が希薄なりレーションや新規取引獲得等により保全に係る交渉が困難となっていることが考えられる。

【図表2】及び【図表3】は、それぞれ業種別貸出残高・残高割合及び業種別保全率を示している。両図表より、正常先・共通貸出先・圏外向けにおいて、金融業向けの貸出残高が大きく、保全率が低いことが分かる。この傾向は、金融業向けの貸出しでは東京所在の大手金融機関向け貸出残高が大きいことが影響している。また、不動産業向けの保全率は比較的高い値を示しているが、同業種では他業種と比べて担保を確保しやすいこと

が要因として考えられる。

【図表4】は、貸出契約開始時期（年度）別保全率を示したものである。これによると、貸出契約開始時期によって保全率が異なっている様子が確認でき、特に正常先においては貸出契約開始時期が近年であるほど保全率が低いことが分かる。他方で、要注先は正常先ほどその傾向は確認されないことから、信用力の高い先に対する担保・保証に依存しない融資が促進されている可能性が示唆される。なお、貸出契約開始時期が2020年度（横軸「2020」）に該当する先の保全率が比較的高い理由は、新型コロナを受けて当該期間において実施されていた、民間金融機関における実質無利子・無担保融資によって、信用保証協会付融資が多く実行されていたためと考えられる。

加えて、本分析では、こうした傾向について企業財務情報や企業規模等の影響を考慮しつつ、特に単独共通別及び越境別に着目し、保全率との関係について回帰分析を用いた検証も行っている。その結果、保全率に影響を与え得る財務情報等と同様であっても、共通貸出先、圏外向けは、それぞれ単独貸出先、圏内向けと比較して保全率が低くなり、特に共通貸出先かつ圏外向けは追加的に保全率が低くなることが示された。

(3) 債務者区分の遷移予測モデル

続いて、債務者区分の遷移パターンごとに行った財務情報で構築される予測モデルの精度検証結果について述べる。当庁がこれまでに公表したFANでは、信用リスクの動向を定量的に把握することなどを目的に、債務者区分に着目した信用リスク推計モデル構築を複数の手法により試みた結果について紹介している。他方で、債務者区分は財務情報以外の定性情報等も勘案して付与されるものであり、財務情報のみに基づいた予測精度

10 本章で使用するデータは、2025年3月期からの本格的なデータ収集開始に向けたデータ精度向上等の取組み途中のものであり、共同DP対象金融機関すべてが集計対象とはなっていないことに起因する。

11 データの制約上、保全率を「(担保額+保証等額+個別貸倒引当金)÷貸出残高×100」で算出している。そのため、一般的な保全率の算出の際分子に含まれている、一般貸倒引当金等が考慮されていない点に留意が必要である。

12 「破綻懸念先以下」とは、共同DPを通じて報告されている債務者区分が「破綻懸念先」、「実質破綻先」及び「破綻先」を合わせたものである。同様に、「要注先」とは、「その他要注先」及び「要管理先」を合わせたものを指す。

は一部債務者区分では低くなる可能性がある。このことを踏まえ、本分析では、財務情報で構築される予測モデルの精度検証を行った。なお、本節で使用するデータは、地方銀行における貸出先のうち、財務情報が取得可能な先に関するデータであり、分析対象期間は2023年9月末から2024年6月末時点（四半期別）である。

本分析では、【図表5】に示す前期（T-1期）から当期（T期）への債務者区分の遷移パターンごとに、財務情報のみを用いた予測モデル（Model 1～4）を作成し、それぞれのROC曲線¹³及びAUC¹⁴から精度を比較することで検証している。予測モデル構築にあたっては、【図表6】に示す特徴量を用いて、ランダムフォレスト¹⁵、XGBoost¹⁶、ロジスティック回帰、サポートベクターマシニング¹⁷（support-vector machine: SVM）及び多層パーセプトロン¹⁸（multilayer perceptron: MLP）といった複数の学習モデルを用いている。なお、各学習モデルの概要は本分析に関するFAN等をご参照いただきたい。

【図表7】に各予測モデルのROC曲線及びAUCを示した。これらを確認すると、Model 2（ランクダウン（破綻懸念先以下））は、Model 1、3及び4（ランクダウン（要注意先）及びランクアップ）と比較すると高い予測精度が示された。このことから、特に破綻懸念先以下にランクダウンするような信用リスクが高い事例に対しては、財務情報のみで精度の高い予測モデルの構築が可能である。一方、債務者区分に関係なくランクアップする際の予測モデルにおいては、財務情報のみでは十分な予測精度は確認できず、その他定性情報等が影

響を与えている可能性が示された。

(4) 小 括

本章では、金融機関の信用リスク管理態勢に係る実態把握を定量データの分析に基づいていっそう進める観点から行った分析として、保全状況に関する分析及び債務者区分の遷移予測モデルの検証について紹介した。前者においては、共通貸出先や圏外貸出先は、単独貸出先や圏内貸出先と同様な財務状況等にあったとしても、保全率が低い傾向があることを確認した。後者においては、債務者区分が破綻懸念先以下にランクダウンする際は、他の遷移パターンと比較して財務情報のみで精度の高い予測が可能であるものの、特にランクアップする際は、財務情報以外の定性情報等を予測モデルに考慮する必要性が示唆された。

なお、これらの結果を解釈するうえでは、以下の点に気をつける必要がある。前者の保全状況に関する分析では、例えば、越境貸出について、各行によって営業基盤とする区域は異なっており、本店所在地外の都道府県への貸出しをもって越境貸出とはいえない場合も含まれている。加えて、保全率は貸出先の財務、リレーション、地域経済状況及び銀行における保全の考え方等を踏まえて調整されるものと考えられる。そのため、繰り返しになるが、本検証は現状の保全の適切性等について論じるものではない点に留意が必要である。

また、後者の予測モデルに関する検証は、ひとつの学習モデルによる比較にとどまっているため、複数の学習モデルを組み合わせることによって精度が向上する可能性がある点（ランダムフォ

13 縦軸に陽性率（真陽性／（真陽性＋偽陰性））、横軸に偽陽性率（偽陽性／（偽陽性＋真陰性））を取り、モデルにおける分類の判定基準を変化させた場合に陽性率と偽陽性率がどのように変化するかを図示したもの。

14 ROC曲線の下部の面積を表し、値が大きいほど予測精度が高いことを意味する。予測の結果と実際の結果が完全に一致する場合に「1」、完全ランダムの場合に「0.5」となる。

15 L.Breiman, 'Random Forests' (2001) 45(1) Machine Learning 5-32

16 T.chen and C.guestrin, 'XGboost: A scalable tree boosting system'; proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining, 785-794 (2016)

17 Vapnik,V.N, *Statistical Learning Theory* (Wiley 1998)

18 【単層パーセプトロンの提唱】 F. Rosenblatt, 'The perceptron:A preobabilistic model for information storage and organization in brain' (1958) 65(6) Psychological Review 386

【バックプロパゲーションの提唱】 D. E. Rumelhart and others, 'Learning representations by back-propagating errors' (1986) 323 Nature 533

レストの結果を踏まえたXGBoostの使用等)や学習に用いたデータの期間が限られていることによるサンプリングバイアスの可能性に留意する必要がある。

これらの結果や留意点を踏まえつつ、当庁では、引き続き、貸出明細等の高粒度データ活用を含む多様なデータ分析に関する実績を積み重ね、金融機関との対話への活用やモニタリングの高度化に向けた取組みを促進していく。

3 地方銀行の貸出明細データ等とマクロ経済指標を用いた信用リスクに関する予兆分析の試行

(1) 目的・概要

足もとにおいて、国内経済は、世界各国における通商政策等の経済政策をめぐる不確実性や地政学リスクの高まりなどが見られるものの、緩やかな回復を続けている。一方で、日本銀行による政策金利の引き上げや、人手不足及び賃上げによる人件費の上昇、物価高による原材料費上昇など、国内企業を取り巻く環境は大きく変化している。こういったなか、国内企業の倒産件数は近年高まりしている。

本章では、こうした状況を踏まえ、将来的な信用リスクの増加等、金融機関の経営に影響を与え得る環境変化を早期に検知することを目標として行った、地方銀行の法人向け貸出明細データと国内外のマクロ経済指標に基づく、1年先における債務者区分下方遷移予測モデル構築を試行した分析について紹介する。

(2) 使用データセット

本節では、予測モデル構築に用いたデータセットやそのなかに含まれる変数について概要を紹介

する。本分析で用いたデータは、大別すると地方銀行の法人向け貸出明細データ等とマクロ経済指標データの2つである。

貸出明細データ等は、全国地方銀行協会の信用リスク情報統合サービス(CRITS)のデータベースから抽出・加工されたデータ及び共同DPにより収集された貸出明細データの2種である。前者は2004年度から2023年度までのデータであり、後者は共同DPが段階的に運用開始された2023年度以降のデータである。このデータの切り替えが、予測モデルの示す結果のうち、2023年度以降の結果に影響を与える可能性には留意が必要である。これに加えて、本分析ではマクロ経済指標データを収集し、その時点におけるマクロ経済状況が債務者区分の下方遷移に与える影響についても取り込めるようモデルの構築を試行している。【図表8】及び【図表9】に、本試行で用いた変数のリストを示す¹⁹。

なお、本分析は予測モデル構築を企図した試行的な取組みであることを踏まえ、広範な業種のうち単一の業種で多くのサンプル数を含む製造業を対象とした予測モデルの構築を行っている。製造業は名目GDPに占める割合が2023年で約2割と最大であり²⁰、かつ、国内銀行から国内製造業に対する貸出金額は2023年3月末時点で64.7兆円であり²¹、本試行におけるモデル構築時では、このうち30.4%(19.7兆円)分をカバーしている。

(3) 機械学習モデル

本試行では、債務者区分を予測対象とし、基準日時点で債務者区分が正常先である債務者が1年後同日時点で下方遷移(以下「債務者区分下方遷移」という。)するか否かを予測するモデルの構築を試行した。この背景としては、一般に、債務者区分の正常先から要注意先以下への下方遷移は、当該債務者の業況悪化を示しており、与信費用の増加

19 本章における機械学習モデルの構築手法、マクロ経済指標の選択にあたっては、2022、2023年度に金融庁が有限責任あずさ監査法人に調査・研究を委託した「AIやICT技術を活用した経営改善支援の効率化に向けた調査・研究」及び「AI技術を活用した経営改善支援の効率化に向けた調査・研究」を参考にしている。

20 内閣府『2024年度(令和6年度)国民経済計算年次推計〈フロー編〉(2025年12月23日)』。

21 日本銀行『貸出先別貸出金』より国内銀行における国内店の銀行勘定のうち、製造業向けを対象とした残高。

によって金融機関の経営状況にも影響するものと考えられるため、本分析の企図するモデルの予測指標として適切と判断したものである。

本分析では、機械学習モデルとして、数多くの機械学習分野の調査・研究で利用されており、高い予測性能を発揮することで知られているXGBoost²²を用いた。学習のために用いたデータの前処理等、本モデル構築の詳細については本分析に関するFANをご参照いただきたい。

(4) 結果

本節では、構築した予測モデルの予測精度及び出力結果について概説する。

ア 予測精度の検証

構築した予測モデルについて、各債務者の債務者区分下方遷移を対象とした予測精度の検証をAUCによって検証した。予測精度確認用データ²³において0.822、結果確認用データにおいて0.773であり、両データに対して比較的高い予測精度をもつことを示唆する結果が得られた。

イ 説明変数の寄与度

SHapley Additive exPlanations (SHAP) 値²⁴に基づく、各変数の債務者区分下方遷移予測への寄与度の確認では、当期利益、支払利息・割引料、営業利益等の財務関連の指標が予測に大きく寄与していることが示された（【図表10】）。一方で、マクロ経済指標はSHAP値で見ると、予測への寄与度は小さく、財務指標と比較して債務者区分下方

遷移を予測する指標としての有効性は相対的に低いことを示す結果となった。ただし、マクロ経済指標のみで学習させたモデルもAUCの値は0.601であったため、一定程度の説明力を有することが示唆されている。

ウ 出力分布の時系列的挙動

【図表11】に、構築した予測モデルによって算出された個々の債務者に対する債務者区分下方遷移の予測確率の平均値を取り、実績と重ねてプロットしたものを示す。予測と実績の推移は似たような動きを示しており、本試行で構築した予測モデルは債務者区分の下方遷移状況を十分に捕捉できていると考えられる²⁵。

また、【図表12】に、当該予測モデルによって算出された個々の債務者に対する債務者区分下方遷移の予測確率について、その分布の時系列推移を示す。これを見ると、2009年度のリーマンショック後で大幅に上昇しているほか、2020年度の新型コロナウイルス感染症拡大期においても小幅に上昇が見られる²⁶。

このうち、2009、2018、2020、2024年度を抽出して、ヒストグラム及び密度分布を描いたものを【図表13】～【図表16】に示す。2018年度は経済状況が比較的安定していたと思われる年度として、その他の年度との対照比較のために用いる。【図表13】の2009年度は高位側に分布が集中し、低位側に向かって緩やかに裾野が広がっている。これは、リーマンショックにより財務状況が悪化

22 前掲注16参照。

23 本分析では、利用可能データの都合上、2022年度分までは①学習用、②予測精度確認用、③結果確認用の3種類に分割し、2023年度分については②予測精度確認用、③結果確認用の2種類に分割している。分割したデータのサンプル数は次のとおり（カッコ内は債務者区分下方遷移先の内数）。

①学習用 【2022年度まで】149,135 (72,820) 先

②予測精度確認用 【2022年度まで】37,284 (18,205) 先、【2023年度】70,948 (6,125) 先

③結果確認用 【2022年度まで】143,194 (10,193) 先、【2023年度】117,871先

なお、①、②の2022年度以前、③については全国地方銀行協会の信用リスク情報統合サービス（CRITS）に登録されたデータベースから抽出・加工されたデータを使用し、②の2023年度については共同DPにおける貸出明細データを使用している。また、③の2023年度については期末の債務者区分が取得不可のため、内数の表記を略している。

24 詳細は、Lundberg, S. and Lee, S. A, 'Unified Approach to Interpreting Model Predictions' proceedings of the 31st International Conference on Neural Information Processing Systems, 4768-4777 (2017)、橋本龍一郎ほか「格付け分類モデルにおける機械学習の応用：機械学習の説明可能性を高める手法」日本銀行ワーキングペーパーシリーズ（2023年）、FSA Analytical Notes (2025.6)「信用保証制度の利用状況に関する実態把握」などを参照。

25 予測が個々の債務者における下方遷移確率を集約（モデルが出力する結果を単純平均）したものであるのに対し、実績は各年度の母数に占める下方遷移先の割合であることから、両者の水準に差が生じる点には留意が必要である。

26 2023年度以降については、モデル構築に使用したデータ変更が影響している可能性があるため、参考値として扱う。

した債務者が多く生じ、全体の下方遷移確率を押し上げたことを示唆していると考えられる。【図表14】の2018年度では低位側に分布が集中しており、高位側に向かって裾野が広がっている。当該年度は、前述のとおり、経済的に安定したと考えられる時期であり、財務状況が悪化した債務者は少なく、全体の下方遷移確率が低下したものと考えられる。【図表15】の2020年度では低位側への分布集中が緩和され、高位側の分布が高まっている。これは、新型コロナウイルス感染拡大による経済的ショックにより、財務状況の悪化した債務者が生じ、全体の下方遷移確率を若干押し上げたことを示唆していると考えられる。

(5) 小 括

本分析では、地方銀行の貸出明細データ等及びマクロ経済指標データを用いて債務者区分下方遷移確率を予測するモデルの構築を試行し、金融機関の経営状況に影響を与えるような国内産業の変化の予兆把握を試みた。データ制約等の課題は残るものの、個別債務者に対する債務者区分の下方遷移について一定の精度で予測可能な機械学習モデルを構築することができ、また、モデルによる予測結果を過去の危機時の傾向と比較することで、足もとの予兆把握において、一定の示唆を得られることを確認した。本分析は試行的に製造業を対象としたが、製造業のなかでも食品、機械等さまざまな分野があるため、業種を細分化し、それに応じたマクロ変数を取捨選択することで異なる結果が得られる可能性がある。また、同様の手法で全産業や製造業以外の業種に拡張するといった応用も考えられる。

しかし、本分析で構築した予測モデルには依然として課題も存在する。1つ目が、予測時点に関する課題である。本分析においては、機械学習モデルの構築にあたり、各年3月末時点を基準日としたデータを学習に用いている。このため、基準

日以降に何らかの経済的ショックが生じた場合、その反映は翌年度のデータによる学習まで待たなければならない。2つ目が、モデルの更新におけるデータの連続性に関する課題である。共同DPのデータは試験的な収集を含めても2023年9月期以降のデータであり、今回の機械学習モデル構築に使用したデータとは不連続であるため今後のモデルの挙動を注視する必要がある。

こうしたことを踏まえ、当庁では、引き続き、足もとの経済状況や貸出先の信用リスク等に関する金融機関との対話に活用すべく、分析対象の拡大や指標の精査、モデルの精度向上等に取り組むとともに、共同DPの本格的な運用開始を踏まえ、貸出明細データの活用可能性を検証していく。

4 地方銀行の住宅ローンのデフォルト状況に関する分析

(1) 目的・概要

近年、マンション価格をはじめとした不動産価格の高騰（【図表17】）や、日本銀行の金融政策変更に伴う市場金利の上昇（【図表18】）など、住宅ローンを取り巻く環境は変化している。これらの市場環境の変化に加え、変動金利選択割合の増加や貸出期間の長期化等の住宅ローンの商品性の変化が、金融機関が抱える住宅ローンに関する信用リスクに対して影響を与える可能性がある。そこで、住宅ローンに係る信用リスクの実態把握を進めるため、共同DPの貸出明細データのうち、地方銀行の住宅ローン債権²⁷を対象として、債務者区分に基づいてデフォルト状況の分析を行った。本章では、その分析について概説する。

(2) デフォルトの定義・分析手法

本分析では、デフォルトした住宅ローンの定義

27 貸出明細データから住宅ローン債権のレコードを抽出するにあたり、住宅ローン債権であると明示的な設定がなされているレコードに加え、元本や金利水準、貸出期間等の条件から住宅ローン債権であると類推できるものは住宅ローン債権として推計を行っている。なお、推計された債権残高、債権数は、既存の収集計表のデータとおおむね整合的な範囲に収まっていることを確認している。

として、「住宅ローン債権債務者の債務者区分が正常先あるいは要注意先だった先が、要管理先以下（要管理先、破綻懸念先、実質破綻先、破綻先のいずれか）に下方遷移した場合」としている²⁸。一般に、住宅ローンのデフォルトは債務者区分のほか、返済の延滞状況、保証会社の保証履行や法的破綻によって判断されることが多いが²⁹、延滞、保証履行及び法的破綻については、貸出明細データの都合上、本稿分析におけるデフォルトの判定で直接参照することは難しく、上記の債務者区分に基づいたデフォルト判定基準を採用している。このことは、最終的には延滞等の状況は債務者区分に反映されることから、本分析結果にも一定程度表れるものと考えられる一方で、債務者区分への反映にタイムラグが生じることも考えると、本分析でのデフォルト数及びデフォルト率は低く見積もられる要因となる可能性があり、本分析の結果を解釈するにあたり留意が必要である。

本分析では、2024年3月末時点进行分析の起点とし、貸出明細データに含まれる住宅ローン債権について、債務者区分が正常先あるいは要注意先である債務者を分析対象としている。そのうえで、2025年3月末時点で、債務者区分が要管理先以下に下方遷移している債務者をデフォルトした先としている。なお、完済等何らかの理由により、2025年3月末時点で貸出明細データに明細情報が含まれない貸出先については分析対象から除くこととしている。

こうして計算したデフォルトした住宅ローン債権について、地域別、実行年度別、実行金額帯別等のさまざまな切り口からデフォルト率の算出・比較することで、住宅ローンのデフォルト状況について実態把握を試みている。

(3) 分析結果

【図表19】に銀行本店所在地に基づく地域別の

集計を示す。この図表から、北海道・東北でデフォルト率が高く、関東で低い結果であることがみてとれる。ただし、本結果を解釈するにあたっては、各地域における地方銀行の住宅ローンシェアの違いや貸出先地域と本店所在地が異なる債権の存在等、必ずしも各地域におけるデフォルト率を表すものではないことに留意が必要である。

実行年度別に集計した場合、2017年度にデフォルト率のピークが確認され、2012年度に底を打っている（【図表20】）。ただし、本結果についても、2025年3月末基準日以前に完済や繰上返済によりすでに対象から外れている借入れが含まれないため、各実行年度のデフォルト率の単純比較は難しい点に留意が必要である。

【図表21】に実行金額帯別の集計結果を示す。この結果から、1千万円未満から5千万円以上の金額帯まで区分しているが、デフォルト率に関して明確な傾向は把握しにくく、金額帯ごとに若干の上下の分布にとどまることが示唆される。

【図表22】に示す貸出期間（住宅ローンの返済期間）の区分による集計結果では、「30年超・35年以下」のカテゴリに住宅ローン債権の集中が見られる。「35年超」カテゴリでは、件数こそ少ないものの、デフォルト率が高い傾向が示される。足もとでは、貸出期間が35年超となる債権の比率が増加傾向にあり³⁰、本結果を踏まえると、今後の動向に注視が必要と思われる。

【図表23】に示す金利種類（固定・変動）の比較では、デフォルト率の水準に差異は見られなかった。一方で、【図表24】のとおり、金利水準別に比較すると、金利水準が高いほどデフォルト率が高くなる傾向が見られた。これを踏まえ、金利種別ごとに金利水準で分割して分析を行うと、【図表25】のように固定よりも変動の方が金利水準の変化に対するデフォルト率の変化度合いが大きいことが示された。変動金利の住宅ローンについて

28 本分析のデフォルト時の債務者区分の設定については、パーゼル規制に基づいている。なお、実務上はデフォルト時の債務者区分を旧金融検査マニュアルにならって破綻懸念先以下とする場合も多い。本分析の実施にあたってデフォルト時の債務者区分を要管理先以下／破綻懸念先以下に設定した場合の結果を比較したが、傾向に大きな変化はなかった。

29 日本銀行「住宅ローンのリスク管理」BOJ Reports and Research Papers（2007年3月27日）。

30 FSA Analytical Notes（2025.1）vol.2「地域銀行の住宅ローンに関する実態把握」。

は、金利上昇局面下で信用リスクが顕在化しやすい可能性がある。

また、【図表26】は、本拠地向け貸出し（本店所在都道府県への貸出し）と越境貸出の比較結果を示す。この結果から、越境貸出におけるデフォルト率が、本拠地向けと比較してやや高い水準であることが見受けられる。

(4) 小 括

本分析では、債務者区分に基づいた住宅ローン債権のデフォルト状況について、さまざまな角度から分析を行い、貸出期間の関連等いくつかの特徴的なふるまいを確認した。これらのデフォルト率が高い傾向にある属性に対する貸出しについては、今後の動向を引き続き注視していく必要があると考えられる。

しかしながら、本分析は単年度におけるデフォルト率を対象としたものであり、より多面的な分析を行うにあたっては、データの収集を進め、時系列変化をより長期間で分析できるようになることが望まれる。また、本分析では地方銀行によって実行された住宅ローン債権を対象として分析したが、今後のデータ蓄積に伴い、他業態の金融機関が実行した住宅ローン債権に対する分析を進めることも考えられる。本分析の結果を解釈するにあたっては、こういったデータの制約を踏まえて、幅をもって解釈することが必要である。

当庁としては、引き続き、住宅ローンの実態把握やリスクへの理解を深め、金融機関のリスク管理やモニタリングの高度化に向けた明細データの活用可能性を検証していく。

5 不動産関連貸出に関する分析

(1) 概 要

本章では、不動産市況を概説するとともに、不動産関連貸出に関する分析を取り上げる。

足もとにおいて、商業用不動産、住宅用不動産

のいずれも趨勢的に価格が上昇しており、それぞれ、特に、商業用不動産では賃貸用アパート・マンション・オフィス、住宅用不動産ではマンションの上昇が大きい（【図表27】、【図表28】）。こうしたなか、国内金融機関の不動産業向け貸出残高は増加し、法人向け貸出残高に占める同貸出しの割合も趨勢的に上昇している（【図表29】、【図表30】）。また、住宅ローン貸出残高も増加傾向にあり（【図表31】）、当庁が2025年1月に公表したFAN「地域銀行の住宅ローンに関する実態把握」では、1件当たり平均実行額及び平均貸出期間の伸長が確認されている³¹。

(2) 不動産業向け貸出しの地理的分布

貸出明細データを用いて、2025年3月末時点の地域銀行の不動産業向け貸出残高について、地域別の構成比を図示すると（【図表32】）、東京都区部、とりわけ都心5区（千代田・港・中央・新宿・渋谷）への貸出比率が大きく、都心5区で全体の約24%を占める。また、貸出しを行った銀行別では、本店所在地が首都圏外の銀行による与信も一定程度確認された。一方で貸出比率が大きい都心5区向けの不動産業貸出の債務者区分において、顕著な信用状況の悪化等は総じて見られなかった。属性別では、コーポレート向けに限ると東京都区部の構成比は約38%に達し、大口先（貸出残高2,000億円以上）を除外しても約32%と高い値である。ただし、個人・個人事業主等に限定すると、東京都区部の構成比は約7%にとどまる。なお、本集計の都市は借り手の登録住所に基づくため、必ずしも資金用途たる事業の所在都市と一致しない点に留意が必要である。

(3) 東京都向け住宅ローンの特徴

前述のとおり、本邦金融機関の住宅ローン貸出残高は趨勢として増加傾向にある。このことを踏まえ、貸出明細データのうち、住宅ローンに関する詳細なデータが存在する地方銀行³²について、直近10年間に実行された住宅ローンの傾向を確認

31 前掲注30。

すると、東京都内では高額な住宅ローンが多数実行されているなどの特徴的なふるまいが見られた³³。そのことを踏まえ、東京都内の市区町村（島嶼部除く）別に、地方銀行が実行した住宅ローンの実行件数・実行額・平均実行額を俯瞰すると（【図表33】）、以下の特徴が見られた。

- ・実行件数は、世田谷区、町田市、八王子市、江戸川区等の、都心5区から一定の距離をおきながらも人口の多い地域³⁴で多く、これらの地域で地方銀行が住宅資金需要に応じて住宅ローンを実行しているものと思われる。
- ・実行額の合計では世田谷区が最も大きく、これは上記市区と比較して同区の平均実行額が相対的に高いことに起因している。
- ・1件当たり平均実行額は、都心5区及びその周辺区で高く、都心部の住宅価格上昇を反映して、地方銀行による実行額も高額化している。

加えて、銀行別に見ると本店所在地が首都圏外の地方銀行による住宅ローンの実行が一定数見受けられた。また、都内の住宅ローンのデフォルト状況を見ると、総じてデフォルト債権の実行額・実行件数は全体に比して小さく、足もとで顕著な信用リスクの高まりは見られないが、FANにおいては住宅ローンは高額化・長期化の傾向にあることが示されており³⁵、信用リスクの状況や借り手の返済負担の増加の可能性等の今後の状況の変化には留意が必要である。

(4) 小 括

本章では、共同DPで収集された貸出明細データ等を用いて当庁が足もとで行っている不動産関連貸出に関する分析について概要を紹介した。本章の上記分析の限りにおいては、不動産関連貸出の積み上がりやポートフォリオに占める割合等の高まりが見られるものの、債務者区分に見られる

貸出先の信用状況の悪化等、本邦金融システム全体の安定性に直ちに影響を及ぼすようなリスクの積み上がりは見られなかった。もっとも、金利及び不動産市場の動向によっては、金融機関の信用リスクに影響を及ぼす可能性や、家計の住宅ローンの返済負担が増加する可能性があることに留意が必要である。

6 おわりに

本稿では、共同DPで収集された貸出明細等の高粒度データ等を対象とし、AIや機械学習等の最新の分析技術を取り入れて当庁が実施した分析のうち、3つのFANに収録された分析及び足もとで行っている不動産関連貸出に関する分析について概要を紹介した。

本稿で紹介した分析は、いずれも共同DPを通じて収集された高粒度データを用いたものであり、金融行政の高度化を企図して行ってきたデータ基盤の充実・強化及び分析力の向上のためのさまざまな取組みが目に見える成果として結実しつつあるものである。分析の結果得られた知見はいずれも、従来の当庁収集データを用いた分析では得ることが困難であったものであり、本取組みの効果の大きさを示唆するものとなっている。

当庁では、本稿で紹介した分析で得られた知見等を活用しつつ、本邦金融システムのモニタリングを行っていくことにより、足もとのリスク要因を丁寧に検証していくことと並行して、生成AI等の最新技術を取り入れた新たな分析手法についても積極的に試行していくことにより、金融行政の高度化の実現を図っていく。

* 本稿において、意見に関する記載は、筆者個人の見解であり、所属組織の見解を示すものではない。

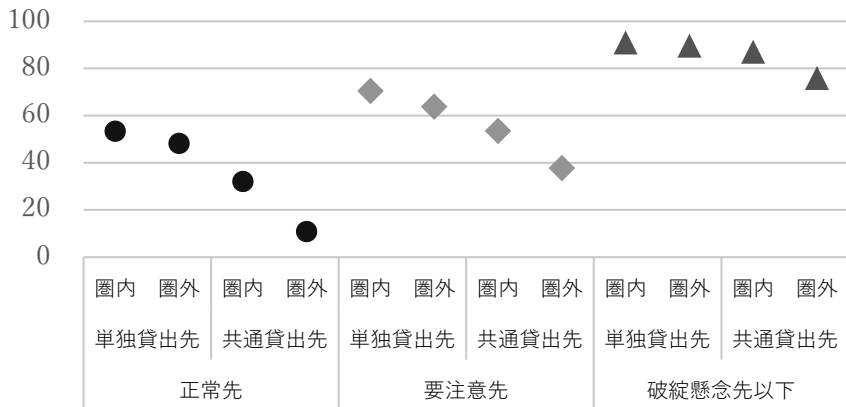
32 必要なデータ項目の欠損等により、一部地方銀行の住宅ローンについては、分析から除外している。

33 データの制約上、本分析では各住宅ローン債権の実行額をもとに分析しており、ペアローン等単一の家計に対して複数の住宅ローンが実行されている可能性については考慮していない。

34 東京都『市区町村統計表』。

35 前掲注30。


【図表 1】 保全率（加重平均）



(表注) 本図表における加重平均は、各カテゴリーに含まれる貸出先の貸出残高を重みとして計算している。

【図表 2】 業種別貸出残高（兆円）・残高割合

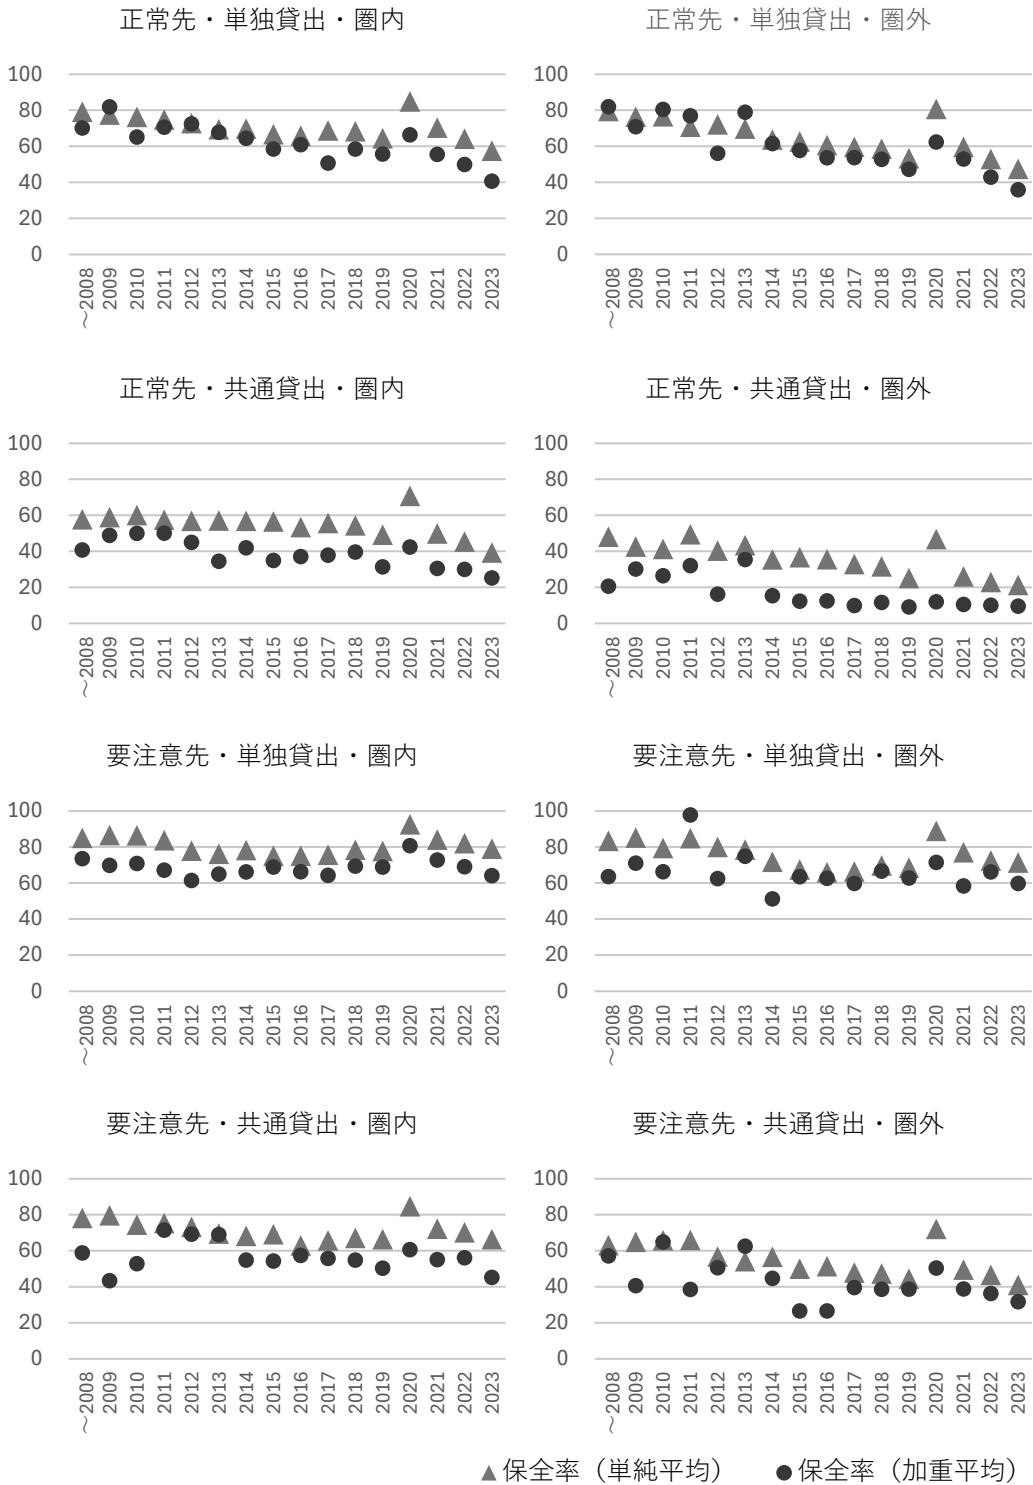
■ 製造業 ■ 建設業 □ 卸売業 □ 小売業
 □ 金融業 □ 不動産業 □ サービス業 □ その他



【図表 3】 業種別保全率

	正常先				要注意先			
	単独貸出先		共通貸出先		単独貸出先		共通貸出先	
	圏内	圏外	圏内	圏外	圏内	圏外	圏内	圏外
製造業	44.8	41.6	22.4	6.5	68.9	64.2	43.7	30.7
建設業	58.3	50.7	38.4	17.5	81.4	73.6	65.5	48.6
卸売業	52.4	40.8	30.1	8.5	76.0	71.1	54.8	38.3
小売業	55.8	48.6	25.5	10.9	81.3	73.0	53.8	32.7
金融業	8.1	8.5	9.5	2.0	17.5	58.8	28.9	26.1
不動産業	69.4	62.3	54.8	22.3	73.2	67.7	66.3	57.0
サービス業	48.3	43.3	31.9	14.0	65.8	58.9	54.2	40.5

【図表 4】 貸出契約開始時期（年度）別保全率



(表注) 本図表における加重平均は、各カテゴリーに含まれる貸出先の貸出残高を重みとして計算している。

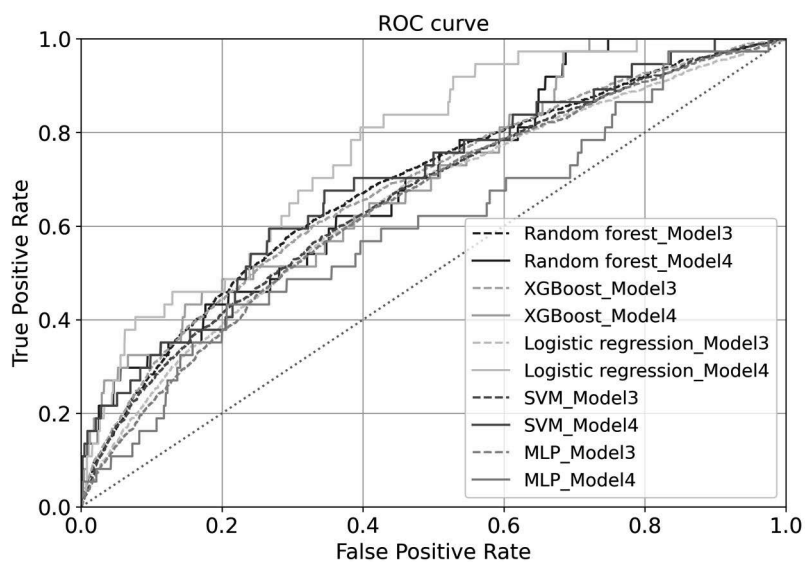
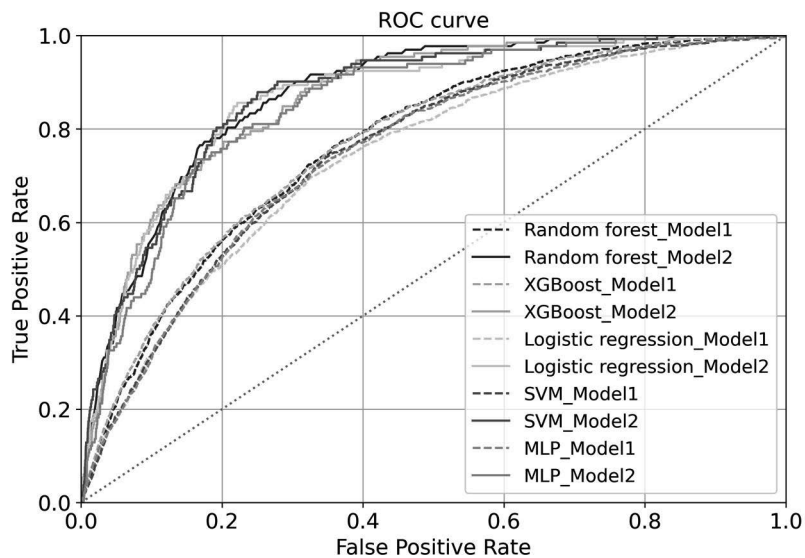
【図表 5】 債務者区分の遷移パターン

予測対象	定義
【Model 1】 ランクダウン（要注意先）	t-1期に正常先であったものの、t期に要注意先へランクダウンした先
【Model 2】 ランクダウン（破綻懸念先以下）	t-1期に要注意先以上であったものの、t期に破綻懸念先以下へランクダウンした先
【Model 3】 ランクアップ（正常先）	t-1期に要注意先であったものの、t期に正常先へランクアップした先
【Model 4】 ランクアップ（要注意先以上）	t-1期に破綻懸念先以下であったものの、t期に要注意先以上へランクアップした先

【図表 6】 特徴量

特徴量	定義
size	資本金の常用対数
ROE	当期利益/自己資本
ROIC	(営業利益+法人税等充当額) / (株主資本等合計+短期借入金+長期借入金+社債)
net DE ratio	((短期借入金+長期借入金+社債) - 現預金) / 純資産
net cash ratio	((現預金+有価証券) - (短期借入金+長期借入金+社債)) / 総資産
capital adequacy ratio	自己資本/総資産
labors share	人件費/付加価値 (付加価値=営業利益+減価償却費+人件費)
DCR	(短期借入金+長期借入金+社債) / (現預金+有価証券+有形固定資産)
sales interest expense ratio	支払利息・割引料/売上高
corporate profit margin	経常利益+営業外費用-法人税等充当額/純資産
common stock ordinary profit ratio	経常利益/資本金
operating cash flow per employee	(当期利益+減価償却費) / 期末役員従業員数

【図表 7】 各予測モデルにおける ROC 曲線及び AUC




	AUC			
	Model1	Model2	Model3	Model4
Random forest	0.77	0.87	0.68	0.69
XGBoost	0.77	0.87	0.68	0.70
Logistic regression	0.74	0.87	0.65	0.77
SVM	0.75	0.87	0.66	0.69
MLP	0.75	0.85	0.65	0.60

【図表 8】全国の地方銀行の法人向け貸出明細データにおける変数（左図）


【図表 9】マクロ経済指標データにおける変数（右図）

NO	指標	分類	NO	指標	分類	出所
001	当期売上高	財務	001	TOPIX	金融	株式会社東京証券取引所
002	当期営業利益		002	Dow Jones Total Stock Market Index		S&P
003	当期利益		003	無担保コールO/Nレート		日本銀行
004	当期減価償却費		004	国債利回り（1年）		財務省
005	当期受取利息_配当金		005	国債利回り（3年）		財務省
006	当期支払利息_割引料		006	国債利回り（5年）		財務省
007	当期総資産		007	国債利回り（米国・5年）		連邦準備制度
008	当期現金_預金		008	国債利回り（米国・10年）		連邦準備制度
009	当期流動資産		009	為替（円/ドル）		日本銀行
010	当期固定資産		010	為替（円/ユーロ）		欧州中央銀行
011	当期流動負債		011	為替（ドル/ユーロ）		連邦準備制度
012	当期固定負債		012	名目実効為替レート		日本銀行
013	当期短期借入金		013	総貸出平残（外債・円貸出）		日本銀行
014	当期長期借入金		014	貸出約定平均金利（新規・短期）		日本銀行
015	当期資本金		015	貸出約定平均金利（新規・長期）		日本銀行
016	当期純資産		016	貸出約定平均金利（ストック・短期）		日本銀行
017	与信残高_総額		貸出	017		貸出約定平均金利（ストック・短期）
018	与信残高_保証協会	018		名目GDP成長率（前年度比）	景気	内閣府経済社会総合研究所
019	保全額_総額	019		名目GDP成長率（前年同期比）		内閣府経済社会総合研究所
020	保全額_保証協会	020		実質GDP成長率（前年度比）		内閣府経済社会総合研究所
021	平均貸出金利	021		実質GDP成長率（前年同期比）		内閣府経済社会総合研究所
022	平均残存期間	022		実質GDP成長率（米国・前期比）		連邦準備制度
023	最大延滞月数	023		実質GDP成長率（ユーロ圏・前期比）		連邦準備制度
024	期末延滞月数	024		実質GDP成長率（アジア・前期比）		連邦準備制度
025	債務者区分	025		業況DI（中小企業・製造業・実績）		日本銀行
		026		業況DI（中小企業・非製造業・実績）		日本銀行
		027		業況DI（中堅企業・製造業・実績）		日本銀行
		028		業況DI（中堅企業・非製造業・実績）		日本銀行
		029		業況DI（大企業・製造業・実績）		日本銀行
		030		業況DI（大企業・非製造業・実績）		日本銀行
		031		景気動向指数CI（一致指数）		内閣府経済社会総合研究所
		032		景気動向指数CI（先行指数）		内閣府経済社会総合研究所
		033		景気動向指数DI（一致指数）		内閣府経済社会総合研究所
		034	景気動向指数DI（先行指数）	内閣府経済社会総合研究所		
		035	中小企業売上見通LDI	日本政策金融公庫		
		036	倒産件数_全国	総務省（東京商工リサーチ）		
		037	倒産負債額_全国	総務省（東京商工リサーチ）		
		038	発電実績_全国	資源エネルギー庁		
		039	公共機関からの受注額	国土交通省		
		040	新設建築物（居住用）床面積_全国	国土交通省		
		041	新設建築物（居住用）工事予定額_全国	国土交通省		
		042	貨物輸送量	国土交通省		
		043	鉱工業出荷指数	経済産業省		
		044	鉱工業在庫指数	経済産業省		
		045	製造工業生産能力指数	経済産業省		
		046	機械受注額（原系列・製造業）	内閣府経済社会総合研究所		
		047	機械受注額（原系列・非製造業）	内閣府経済社会総合研究所		
		048	第3次産業活動指数（第3次産業総合）	経済産業省		
		049	商業販売額_商業計	経済産業省		
		050	商業販売額_卸売業計	経済産業省		
		051	商業販売額_小売業計	経済産業省		
		052	訪日外客数_総数	日本政府観光局（国際観光振興機構）		
		053	旅客輸送量	国土交通省		
		054	消費者態度指数	内閣府経済社会総合研究所		
		055	国内企業物価指数（総平均）	日本銀行		
		056	地価_全国	国土交通省		
		057	WTI原油価格	米国エネルギー情報局		
		058	完全失業率（原数値）	厚生労働省		
		059	労働力人口（原数値）	厚生労働省		
		060	新規求人数	厚生労働省		
		061	有効求人倍率（原数値）	厚生労働省		
		062	将来人口推計（t+1期集計）_全国	国立社会保障・人口問題研究所		
		063	住民基本台帳人口_全国	総務省		
		064	失業率（米国）	連邦準備制度		


【図表 10】 予測への寄与が大きい変数




【図表 11】 債務者区分下方遷移に関する予実比較




【図表 12】 機械学習モデル算出の債務者区分下方遷移の予測確率の分布推移



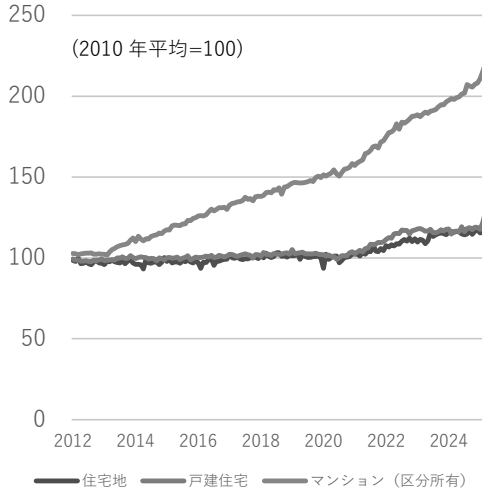
【図表 13・14】 債務者区分下方遷移確率分布（2009年度 [左図]、2018年度 [右図]）



【図表 15・16】 債務者区分下方遷移確率分布（2020年度 [左図]、2024年度 [右図]）



【図表 17】不動産価格指数推移




【図表 18】市場金利推移




(出所) 【図表 17】国土交通省、【図表 18】財務省、日本銀行。


【図表 19】本店所在地域別のデフォルト状況




【図表 20】実行年度別デフォルト状況推移




【図表 21】 実行金額別のデフォルト状況




【図表 22】 貸出期間別のデフォルト状況




【図表 23】 金利種類別のデフォルト状況




【図表 24】 金利水準別のデフォルト状況



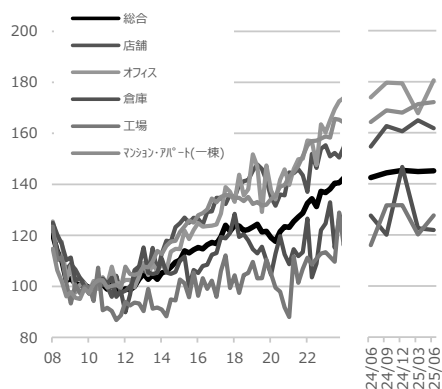
【図表 25】 金利種類・水準別のデフォルト状況




【図表 26】 貸出先地域別のデフォルト状況



【図表 27】 商業不動産価格指数



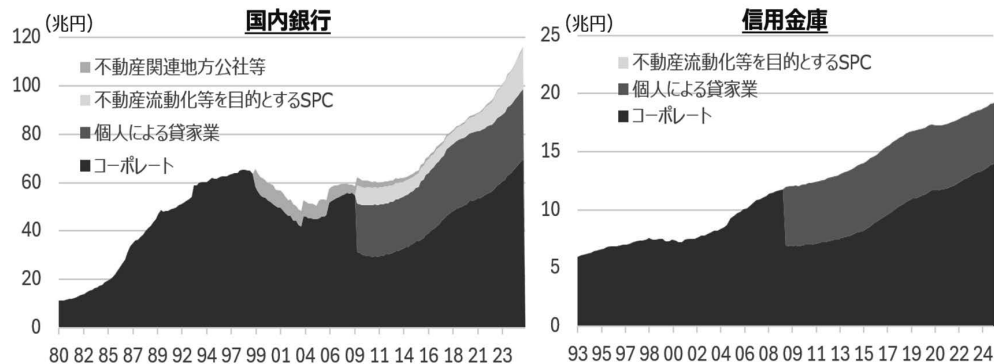
【図表 28】 住宅用不動産価格指数



(表注) 2010年平均を「100」として指数化。

(出所) 【図表 27】、【図表 28】とも国土交通省。

【図表 29】 不動産業向け貸出残高

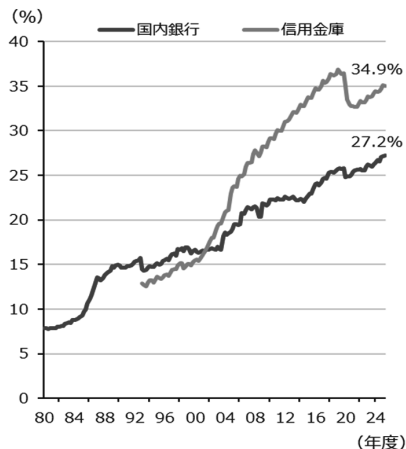


(表注) 左図の「国内銀行」はゆうちょ銀行を除く銀行。右図の「信用金庫」は日本銀行と取引のある信用金庫。

左図の貸出残高は定義変更により、1993年度より貸出残高に当座貸越が追加。

(出所) 日本銀行データをもとに金融庁計算。


【図表 30】 不動産業向け貸出残高



(表注) ここでは、法人向け貸出残高(総貸出から地方公共団体・個人・海外円借款を除外したもの)に占める不動産業向け貸出残高の割合によって計算している。


(出所) 日本銀行データをもとに金融庁計算。

【図表 31】住宅ローン貸出残高



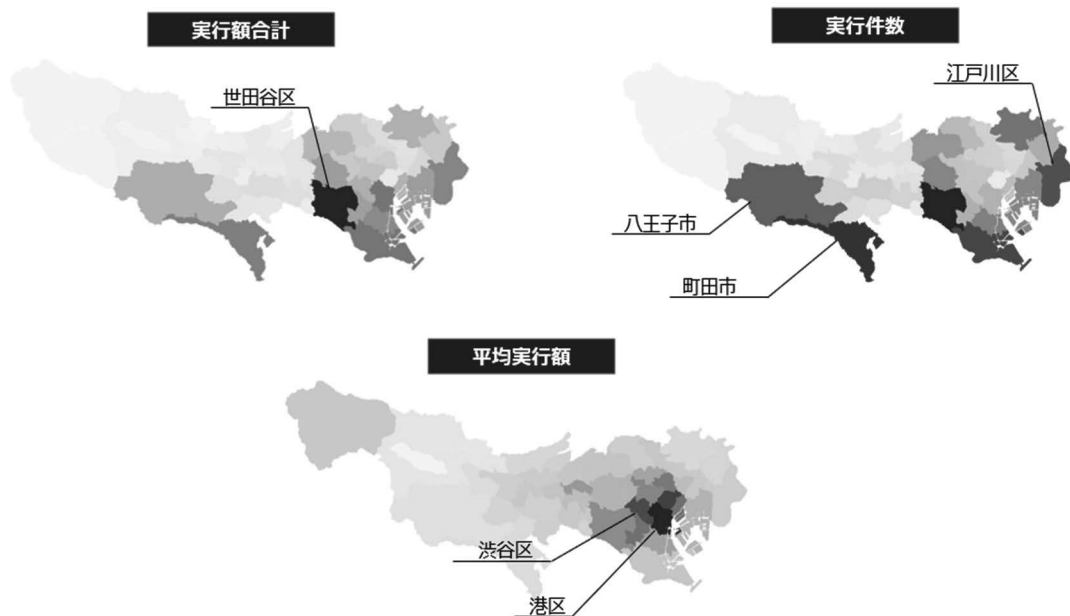
(出所) 住宅金融支援機構。

【図表 32】地域銀行の不動産業向け貸出残高における地域別構成比



(出所) 金融庁。

【図表 33】 東京都内住宅ローン実行額、実行件数及び平均実行額（島嶼部除く）



(表注) 各図表とも色が濃い市区町村ほど金額／件数が多いことを表す。

可視化にあたっては株式会社 GRI の地図情報データを使用。

(出所) 金融庁。