

---

金融政策の波及効果及び  
企業ミクロデータ構造化のための  
統計的手法の改善に関する研究

園田桂子

博士（統計科学）

総合研究大学院大学  
複合科学研究科  
統計科学専攻

令和5年度（2023年度）



## 概要

金融政策効果の検証は、これまで主に集計データに基づいて行われてきた。これは、金融政策が、インフレ率、GDP ギャップ、金利といったマクロ経済や金融の安定を目指すものであり、その安定度合いの把握も、消費者物価指数のヘッドライン、GDP、代表的な金利といった、集計データや代表的なデータで測っていることに加えて、金融政策の政策手段が、直接ミクロ経済主体に対して行われるものではないことと関連している。しかし、2008年のリーマンショック時に、経済主体が連鎖的にショックを受けてからは、ミクロとマクロのつながりへの関心が高まった。政策立案の立場でも、金融政策がどのような経路で経済主体の間に波及しているのか、ミクロデータに基づく実証研究が求められるようになった。

第1章では、ミクロデータを用いた政策効果の検証について、経済分野におけるこれまでの取り組みの流れを紹介しつつ、その課題について述べている。ミクロデータ分析は、それまでの集計データに基づく分析と比較して、企業や個人といった経済主体の行動理論とデータの結びつきを強め、経済主体毎の異質性を反映することを可能にした。しかし、経済分野では、統計モデルを用いる際に、データが確率モデルに基づいて生成されたと仮定する考え方が主流で、経済理論に基づく回帰モデルのような、モデルベースの研究を進めてきたこともあり、機械学習のようなデータ適合的なモデルを体系的に探索する手法の取り入れは早くなかった。また、公的機関や民間のデータベンダーが提供するデータの中に、政策効果を分析するという目的に合致したデータが存在することはまれであり、分析者自ら複数のデータベースをリンケージさせて、分析に有用なデータを構築する必要がある。

第2章では、完全照合によって、企業の財務データと、銀行の財務データと、企業の金融機関別借入金データをリンケージさせて、金融政策が企業と銀行の取引関係にどのような影響を与えたかを分析できるデータを構築した。また、金融政策について、緩和、引き締め、中立の別に実施を表す離散変数を作成した。分析手法としては、統計的因果推論の枠組みで、観察データに基づく因果効果の分析を行った。分析の結果、企業のバランスシートを通じた金融政策の介入効果があることが示唆されたものの、その影響度合いは大きくない

ことがわかった。

第3章では、よりアルゴリズムの特性を生かして、データ適合的にランダムフォレストを構築し、企業の借入前年比が増加するか否かを示す離散変数を被説明変数とした金融政策の実施に対する感度分析を行った。感度分析には、金融政策単独の影響を見るための **Partial Dependence Plot** と、金融政策とその他変数の交互作用を表す **Accumulated Local Effects Plot** を用いた。分析の結果、第2章で行った分析の結果と同様に、企業のバランスシートを通じた金融政策の介入効果があることが示唆されたものの、その影響度合いは大きくないことがわかった。また、銀行の資金供給よりも企業の資金需要を通じた影響が強いことがわかった。一方、金融政策は引き締めや緩和の水準や変化の幅というよりも、政策を転換したことが影響を与えている可能性があることと、緩和的な金融政策下では規模が小さい銀行や保有流動性が低い銀行が企業向け融資をより活発に行うことが示唆された。

第4章では、政策立案の立場からのより具体的な関心に答える分析を可能にするために、Takabe and Yamashita (2020) が提示した、多項ロジットモデルを用いた統計的マッチング手法を、民間データである日経 NEEDS 社 FinancialQUEST の企業財務データベースと、公的データである経済産業省企業活動基本調査に適用した。この際、正しいマッチング相手の正解率で測ったマッチング精度を向上させるために、先行研究が用いた変数を参考にしつつ、設立年度についてグループ化せずにそのまま用いたほか、住所についても行政区域別でなく郵便番号を用いたところ、先行研究が中小企業に適用した際の精度よりも高く、約9割の正解率を達成した。また、先行研究では、マッチング確率の上位20位まで、順位を増やすごとに正しいマッチング相手が含まれる確率を高めるのに対して、本研究では上位1~2位で約9割の正解率に到達した。多項ロジットモデルは、異なるデータベースに含まれる企業全ての組み合わせについて、マッチング確率を計算する。このマッチング確率に基づいて、どのレコードとどのレコードをマッチングさせるかという問題は、マッチング確率を重みとした重み付き2部グラフの最適マッチングと捉えることができる。先行研究は、レシピエント側の重複を許さない1対1の制約を付けたことを意味するハンガリー法を推奨しているが、本研究では、目的関数と重複制約の妥当性を検証する観点から、先行研究が推奨するハンガリー法と、Gale-Shapley のアルゴリズムと、整数線形計画法をソルバーで解いた結果とを比較検討した。この結果、目的関数とは関係なく、レシピエント側の重複を許す1対多のマッチングが精度を向上させることを明らかにした。このように、企業マイクロデータ構造化の推進に資する、企業データに適用する統計的マッチング手法の精度を向上させる方法を提示した。また、本研究での適用事例に

よって、金融政策が銀行の資金供給、企業の資金需要にどのような影響を与えるのか、影響があるとすれば、企業の資金需要は投資のような前向きな資金需要であるのか、政策立案の立場からみてより具体的な関心に答える分析が可能になったと考えている。

以上の結果を踏まえて、第5章では、本研究の成果について総括するとともに、今後の展望について述べている。まず、近年の状況を踏まえて、金融政策の波及効果を分析する際に使用する変数について、金融政策変数と、被説明変数である企業の借入前年比と説明変数である金融政策変数の両方に関連する共変量のいずれについても再検討する余地がある。特に共変量については、2020年以降、コロナ感染症の世界的拡大によって世界的に経済活動が縮小した後、ウクライナにおける戦争がエネルギーや商品価格等を通じて世界的なインフレを起こすなど、世界同時的なショックを受けて、規模や同時性において例を見ないほどの金融緩和が世界各国で導入されている。また、現在、世界的な金融緩和の後に各国が固有の状況を踏まえて微妙な舵をとりながら金融引き締めに変換している状況において、他国の金融政策の変更が為替や金利、金融その他商品価格を通じて日本経済に瞬時に大きな影響を及ぼし得るようになってきている。このことを考えると、海外の金融政策や国際金融市場の状況を取り込むなど、共変量を再検討するべきタイミングであると考えられる。

また、統計的データマッチング手法によって拡充したデータを分析に活用して、情報量が増えたデータを用いることの有用性を示していくことも重要な課題である。多項ロジットモデルを用いた統計的マッチング手法は、モデルの推定を行うために完全照合を行うための正解データを必要とする。しかし、正解データがない場合もマイクロデータ構造化に組み入れるために、正解データがある他の国内企業データについて適用事例を重ねていけば、ある程度安定したパラメータを得ることができると考えられる。また、必ずしも同一の企業同士をマッチングさせることにこだわらず、似通ったグループごとマッチングさせるなど、データ融合の枠組みでのデータベース拡張も検討の余地がある。この観点から、本研究で検討したレシピエント側の重複を許す1対多のマッチングを活用することも考えられる。今後も様々な統計的マッチング及びデータ融合の手法を組み合わせ、利用可能なデータを拡大してゆく必要があると考える。

# 目次

概要 .....	i
第1章 序論 .....	1
1.1 経済分野におけるマイクロデータ分析 .....	1
1.1.1 経済分野における伝統的なマイクロデータ分析 .....	1
1.1.2 アルゴリズム的判別手法の適用可能性 .....	2
1.2 ミクロデータ利用の現状 .....	4
1.2.1 日本銀行におけるマイクロデータの扱い .....	5
1.2.2 民間データと公的データの特徴 .....	6
1.3 企業マイクロデータの構造化 .....	7
1.4 本論文の構成 .....	9
第2章 企業-銀行間のデータリンケージと統計的因果推論による金融政策効果の検証 .....	13
2.1 導入 .....	13
2.2 先行研究と課題 .....	15
2.2.1 パネル回帰分析による先行研究と課題 .....	15
2.2.2 機械学習を適用した先行研究と課題 .....	16
2.2.3 統計的因果推論による方法と課題 .....	17
2.3 完全照合によるデータリンケージ .....	17
2.3.1 元となるデータの属性 .....	17
2.3.2 2次元配列へのデータリンケージ .....	18
2.3.3 変数選択と欠損値への対応 .....	21
2.3.4 外れ値への対応と変数変換の適用 .....	21
2.4 ルービンの因果効果による金融政策の波及効果の推定 .....	27
2.4.1 因果効果と推定モデル .....	27
2.4.2 分析の概要 .....	27
2.4.3 推定に用いる変数 .....	30
2.4.4 因果効果の推定で仮定する変量間の影響関係 .....	32
2.4.5 傾向スコアと平均処置効果の推定方法 .....	33
2.4.6 モデルの推定結果と考察 .....	34
2.5 まとめと今後の課題 .....	38
第3章 ランダムフォレストの感度分析による金融政策効果と波及メカニズムの検証 .....	41
3.1 導入 .....	41

3.1.1 分析の概要 .....	41
3.2 ランダムフォレストと勾配ブースティングによる分類推定.....	42
3.2.1 推定に用いる変数 .....	47
3.2.2 感度分析の方法 .....	47
3.3 モデルの推定結果.....	48
3.3.1 感度分析の結果 .....	50
3.3.2 感度分析の結果から見た金融政策効果と波及メカニズムの考察...56	
3.4 まとめと今後の課題 .....	57
第4章 企業マイクロデータ構造化のためのマッチング確率を用いた重み付き 2部グラフの最適マッチング手法の検証 .....	59
4.1 導入.....	59
4.2 先行研究と課題 .....	61
4.2.1 多項ロジットモデルによる統計的マッチングの先行研究と課題...61	
4.2.2 重み付き2部グラフの組み合わせ最適化を用いたマッチングの先 行研究と課題.....	62
4.3 多項ロジットモデルによるマッチング確率の推計 .....	63
4.3.1 類似度を測る距離 .....	63
4.3.2 多項ロジットモデルを用いた統計的マッチングのモデル .....	64
4.3.3 多項ロジットモデルを用いた統計的マッチングにおけるウェイト 推定 .....	65
4.3.4 分析に用いるデータ .....	66
4.3.5 分析に用いる多項ロジットモデル .....	68
4.3.6 多項ロジットモデルの推定結果 .....	69
4.3.7 複数手法のマッチング精度比較 .....	72
4.4 マッチング確率を重みとした2部グラフの最適マッチングのアルゴリ ズム比較.....	78
4.4.1 分析に用いるデータ .....	78
4.4.2 比較するアルゴリズム .....	79
4.4.3 各アルゴリズムによる正解率比較 .....	83
4.5 まとめと今後の課題 .....	83
第5章 総括 .....	86
5.1 本研究の成果 .....	86
5.2 残された課題 .....	88
5.3 今後の展望.....	89

## 図表目次

図表 1 本論文の構成 .....	11
図表 2 金融政策の主なトランスミッションメカニズム .....	15
図表 3 データのリンケージ方法 .....	19
図表 4 変数一覧 .....	23
図表 5 因果効果の推定で使用する金融政策変数 .....	31
図表 6 因果効果の推定で想定する変量間の影響関係 .....	32
図表 7 因果効果の推定結果（平均処置効果） .....	35
図表 8 決定木ベースのアルゴリズム .....	43
図表 9 決定木モデルのハイパーパラメータの候補と選択（下線） .....	46
図表 10 決定木モデルの評価 .....	49
図表 11 マクロ経済変数と金融政策変数に対する Partial Dependence Plot .....	51
図表 12 マクロ経済変数と金融政策変数に対する Accumulated Local Effect (ALE): Main Effect.....	53
図表 13 金融政策変数に対する Accumulated Local Effect (ALE): Second- order.....	54
図表 14 距離の定義に用いる記号の意味 .....	63
図表 15 学習データとテストデータのレコード数 .....	68
図表 16 距離関数に含まれる記号の定義 .....	68
図表 17 多項ロジットモデルの推定結果 .....	70
図表 18 Takabe and Yamashita（2020）での中小企業についての推計結果 （3地域にわけたデータセットのうち一つに適用した結果） .....	71
図表 19 マッチング正解率比較 .....	74
図表 20 Takabe and Yamashita（2020）での中小企業についての推計結果 （3地域にわけたデータセットのうち一つに適用した結果） .....	76
図表 21 上位1位の正解率 .....	77
図表 22 Takabe and Yamashita（2020）での中小企業についての推計結果 .....	77
図表 23 使用するデータのイメージ .....	79
図表 24 各アルゴリズムの正解率 .....	83



# 第 1 章

## 序論

### 1.1 経済分野におけるマイクロデータ分析

#### 1.1.1 経済分野における伝統的なマイクロデータ分析

経済分野におけるマイクロデータ分析は、主に、マイクロデータの利用が可能な公的機関に関係する研究者によって、様々な種類の政策介入を評価するために取り組まれてきた。集計データを用いた時系列分析も、公的機関に関係するか否かに関わらず多くの研究者によって、経済理論と統計的手法を組み合わせて、政策の設定や評価のために行われたが、統計的モデルと経済理論との関連は弱く、経済主体の意思決定との関連性も明確でなかった。これに対して、マイクロデータ分析は、データ駆動的に個々の経済主体の行動を定式化したモデルを開発し、個人、家計、企業といった個々の経済主体の行動理論とデータを結びつけて、経済理論とマイクロデータの結びつきを密接にした。マイクロ計量経済学の研究者が行った同分野での重要な発見は、それまでの経済理論が、裏付けに欠いたまま「代表的な（平均的な）経済主体」を用いてきたのに対して、経済主体の経済活動における異質性と多様性を証拠づけたことだとされている（Heckman, 2000）。

また、マクロ政策評価という目的において、集計データによる時系列分析を行う研究者が経験主義的なアプローチを採り、線形方程式によるモデルを構築することで因果関係（時差相関関係）を実証しようとしたのに対して、マイクロデータ分析を行う研究者は、特定の政策課題に答えるためには、経済変数間の関係を完全に数式で表した構造モデルを作るのではなく、問題固有のパラメータ（処置効果）を重視すればよいと考えた。すなわち、集計データによる分析を行う研究者が、①政策を実施した場合に、実施群と非実施群に違いがあるか（既存の政策の有効性を評価する）という問題と、②新しい政策や既存の政策を新たな状況で適用した場合にどのような効果が期待できるか（既存の政策が過去に経験

した環境と異なる環境で有効かを予測する、または、経験のない新しい政策の効果を予測する) という問題の両方に対して、構造モデルで答えを得ようとしたのに対して、マイクロデータ分析を行う研究者は、①のみに答えることを目的としたツールとして進化させてきた。このために、構造モデルの仮定をノンパラメトリックに拡張した結果、現在も実証研究で広く用いられているのが、パネル回帰分析と、サンプルの偏りを修正するためのヘックマンの二段階推定 (Heckman, 1974) と呼ばれる手法である。なお、構造モデルの利点は、経済理論の検証や、理論内の変数の相対的重要性についての定量的な評価を行うことができる点にあり、与えられた経済環境でモデルのパラメータを推定して、異なる環境での効果の予測に用いたり、新たな政策の効果の予測に用いることができる。

### 1.1.2 アルゴリズム的判別手法の適用可能性

本研究も、過去に行った金融政策の効果をマイクロデータから検証するものである。しかし、マイクロデータから因果推論を行う際の伝統的なツールであるパネル回帰分析に代わって、機械学習の手法を適用する。狭義の機械学習は、データセットに適用するように設計されたアルゴリズムを開発する分野で、主に予測、判別・分類、クラスタリング (グループ化) といったタスクを対象とするものである (Athey, 2018)。このうち教師なし学習では、特徴量が似ている観測データのクラスターを見つけて次数を削減する。教師あり学習では、特徴量とともに観測されているラベル付きの結果を使って学習し、独立したデータセットについて判別・分類または予測する。本研究が用いるのは後者である。但し、目的は独立したデータセットに最も適合するモデルを選択して予測に用いることではなく、因果推論である。

回帰分析では、欠落変数がある場合や、システムが連立方程式で記述される場合等に、誤差項とは無相関で、回帰変数の変動に関する情報を持つ変数 (操作変数) を取り入れることで、回帰変数と誤差項が相関していてもパラメータの一致推定量を得ようとする。予測と因果推定との違いという点では、操作変数を取り入れた回帰モデルの説明力 ( $R^2$ 等) は、一般に最小二乗法を用いた予測モデルに比べて低く、因果関係のパラメータの不偏推定のために予測精度は犠牲にしているといった違いがある (Athey, 2018)。なお、因果関係を分析しようとするパネル回帰分析は、操作変数として、時間にレコード数を乗じた膨大な数のダミー変数を取り入れることが多いが、それらは、他の説明変数が担うべき要因

を説明している可能性がある。

これに対して、予測精度が高いことが特徴の一つである機械学習を因果関係の推定に用いる利点は、データ駆動的に最適な関数形の探索を体系的に行うことができる点である。他方で、因果関係の仮定が誤っていても、データ適合的なモデルを体系的に選択するため、学習データでもテストデータでも偏った結果を算出する可能性があることには注意を要する。機械学習を用いるもう一つの利点に、計算の効率性がある。目的関数をパラメータに関して最適化する際に確率的勾配降下法を利用することで、計算コストが高く、従来のアプローチでは困難であった非常に複雑なモデルの推定が可能となる点である。

応用経済学分野で政策評価のために用いられる因果関係の検証ツールは、Mullainathan and Spiess (2017)がレビューしている。この中で、観測データによる因果関係の検証について、回帰不連続法 (regression discontinuity)、合成コントロール法 (synthetic control)、政策評価などで介入の対象となるグループの質的差を考慮して、政策介入後の差と政策介入前の差を介入効果の推定値とする差分の差法 (differences-in-differences methods)、ネットワークによる因果探索 (methods designed for networks settings)、そして、実験データと観測データを組み合わせる手法が紹介されている。本研究は、一つ目の分析として、統計的因果推論の枠組みで、差分の差法の考え方に基づくルービンの平均処置効果 (Rosenbaum and Rubin, 1983) を推定する。なお、統計的因果推論は、共変量という、被説明変数と説明変数のどちらにも関連する変数の影響を除去して、被説明変数と説明変数の関係を明確にするものであり、両者の相関関係を明らかにするものである。しかし、金融政策に効果がなければ相関関係も見いだせない。この枠組みを適用するにあたって重要なのが、共変量の影響の除去である。実験データであれば、企業を政策実施群と非実施群に無作為に割り当てて、企業の借入の増減データを得ることができるが、金融政策の効果を、観測したマイクロデータから分析するためには、無作為割り当てを行ったわけではないことに伴う偏りを調整する必要がある。調整のためには、時期や場所が違っても、政策実施群とみなせるデータと、非実施群とみなせるデータとが必要になるが、金融政策は常にアクティブな政策であり、時間や地域によって実施されている時とない時があるわけではないことから、研究デザインによる調整を行うことも難しい。このため、統計的調整を行う必要がある。統計的調整法には、共分散分析的な手法があるが、被説明変数 (従属変数) と共変量との関係を既知の回帰関数でモデル化する必要がある。また、こ

うして分析したとしても、群間の切片の差が因果効果と等しいとは限らない。そこで、傾向スコアを用いた調整を行う。傾向スコアは、所与の共変量の下でそのデータが政策実施群(非実施群)に属する確率を表す。この傾向スコアの逆数による重み付き平均によって、因果効果を推定する。この手法では傾向スコアを推定する必要があるが、本研究では一般的に用いられるロジスティック回帰ではなく、モデルを設定する必要がないランダムフォレスト回帰を行った。これは、モデルの誤設定による誤りを防ぐという目的によるものである。なお、金融政策は複数の手段を組み合わせで行われることから、本研究では、ある期間において、引き締め、緩和、中立的のいずれの金融政策が採られていたかを表す離散変数を作成して用いた、被説明変数は、企業の借入前年比を連続変数としてそのまま用いた

因果関係の検証に機械学習を利用するもう一つの方法は、解釈や説明が容易な因果関係モデルをたてて機械学習で推定するのではなく、機械学習の手法で過去のデータに適合的なモデルを探索した後に、モデルの因果関係の解釈可能性を考える方法である。その一つの手法として、金融政策変数が他の変数と相関していない事を仮定して、金融政策変数の値のみが変化した時に、被説明変数である企業の借入前年比が増加する確率が平均してどう変化するかを推定したり、金融政策変数が他の変数と独立ではなく、かつ交互作用を持つと仮定して、金融政策変数単独の効果と、交互作用とをそれぞれ別に推定する感度分析を行う方法がある。これは、経済理論に基づいたモデルを構築するのと異なり、固定観念に頼る可能性が低いアルゴリズムの特性をそのまま利用する方法であり、本研究でも検証する。この分析では、企業の借入前年比を0以下であれば0、プラスであれば1の離散変数に変換して被説明変数とした上で分析した。これは、企業、また銀行にとっても、貸借取引を維持することにメリットがあるなどの理由で、企業が每期、借入のうち金利分だけを返済するなどして、借入前年比が変化しないケースが多い中、金融政策の効果を知るには、企業が借入を増やすか否かという離散的な意思決定に影響を与えていると捉える方が適切な可能性があると考えたためである。

## 1.2 ミクロデータ利用の現状

ミクロデータ分析を経済分野で行うミクロ計量経済学の発展のきっか

けになったのは、マイクロ調査の開始とコンピュータの導入、重回帰分析の開発と普及によると言われる (Heckman, 2000)。これによって数百本の重回帰モデルの推定が可能になったものの、このままでは膨大な数のデータを解釈して政策的なコンセンサスの形成に利用することは困難であり、低次元で、経済学的に解釈可能なモデルへの需要が生まれた。ここで強調したいのは、マイクロデータが利用可能になったこと（と計算機の発展）が政策効果の検証を進歩させた点である。以下では、マイクロデータの利用の現状について概観する。

### 1.2.1 日本銀行におけるマイクロデータの扱い

日本銀行では、業務目的で様々な統計を作成している。企業データに関しては、企業動向を的確に把握し、金融政策の適切な運営に資することを目的として、全国企業短期経済観測調査（短観）を行っている。しかし、金融政策はインフレ率、GDP ギャップ、金利といった、マクロ経済や金融を安定させることを目的としていることから、データは集計のために収集されており、マイクロデータのまま分析されることを予定していない。また、金融政策として、過去に不動産向け貸出に絞った窓口規制を行った例や、現在も成長基盤強化や貸出増加のための資金供給、有価証券の買い入れといった、特定の業種や特定の性質を持つ、あるいは特定の基準をクリアした企業をターゲットにした手段はあるものの、いずれも金融機関や金融市場を通じたオペレーションであり、直接マイクロ経済主体に対して行う政策手段ではない。このため、政策立案にあたってマイクロレベルでの現状把握が重要と認識しながらも、そうした情報は支店や本店で行う地域経済調査で行う経営者へのインタビュー等の質的情報の収集に頼り、データに基づく分析は、集計値を対象とする体制になっている。

こうした体制になっている背景には、データの利用可能性が著しく制限されていることもある。日本銀行は、統計法の規定によって、調査対象企業から回答を受けた秘密事項を厳正な管理によって保護することが義務付けられている。このため、収集されたデータは、集計値、マイクロデータとも調査担当部署の者以外は物理的にも電子的にもアクセスできず、学術研究目的でのデータ提供もされていない。このため、研究のためには、国が行う統計調査の調査票情報（マイクロデータ）について、2019年5月以降、学術目的での利用が可能になったことを好機にこれを利用するか、または民間のデータベンダーから入手できるデータを利用する

必要がある。

## 1.2.2 民間データと公的データの特徴

### 母集団との関係

ここでは、企業に関するマイクロデータのうち、調査元が民間企業であるデータを民間データ、公的機関であるデータを公的データと呼ぶ。母集団との関係で比較すると、民間データは、CRD 協会のデータ（信用保証協会及び金融機関が取引先中小企業の財務データ・非財務データ・デフォルトデータを提供しており、ほぼ全数調査に近い）を除けば、帝国データバンクや東京商工リサーチといった調査会社が、有価証券報告書等の公表データを収集し、また、独自の信用調査情報を加えるなどしたもの、自社または他のデータベース事業者を通じて利用者に提供しているものである。これらのデータは、有価証券報告書等の公表が義務付けられている上場企業については全数調査に近いものの、非上場企業等それ以外の企業のデータは、標本理論に基づかずに収集されているか、収集されていない。これに対して、公的データは全数調査であるか、そうでない場合は標本理論に基づいた調査設計の下で収集されている。

### 調査項目のカバレッジ

調査項目に関して比較すると、民間データは、データベース利用者の経営上の関心事（与信診断、マーケティング強化、M&A、企業誘致、リスクヘッジ等）に応えるべく、仕入先、販売先、主要株主といった企業間の相関関係がわかる情報や、倒産企業の債権者名簿などを含み、公的データよりも幅広い情報を持つ場合が多い。これに対して、公的データは主に行政施策の企画・立案・評価を目的に行われる調査のデータであることから、マクロの視点から有用と考えられる項目に限られるほか、秘匿の要請もあって、親会社・子会社といった一般に公表されている情報を除けば、企業間の取引関係に関する情報はほとんどない。また、公的機関が行う全ての統計調査についてマイクロデータが提供されているわけではない。提供されていても、法人企業統計調査のように、名称や住所等、企業が特定できるような情報は提供されないなど、調査によって取り扱いにばらつきがある。

## 利用にかかるコスト

民間データを利用するために必要なコストは、基本的には利用契約にかかるコストやデータベース利用料である（学術目的の利用は無料のCRD データを除く）。公的データを利用するために必要なコストは、各省庁の委託を受けて公的統計のマイクロデータの提供を行う独立行政法人統計センターが定める手続きに従って利用許可を得る必要があるなど、手続きコストがかかるほか（統計センターが行う事務手続きに対して定められた基準で金銭的な対価を払う必要もある）、企業名が識別できる状態で利用する場合は、オンサイト施設でのみ利用可能であるなど、利用上の制限がある。一般に、民間データの方が金銭的なコストが高く、個人で負担するのは困難であるが、公的データ（民間データで学術目的の利用が無料で認められるCRD データもこちらに含む）も、個人で利用許可を得るためには、所属する組織の裏書を求められるなどのハードルがある。

## 1.3 企業マイクロデータの構造化

利用コストが両建てでかかることを除けば、民間データと公的データを統合することは、母集団からの偏りを修正する情報を得ることができるほか、情報量を拡大することができて、有用なデータを構築することができる。近年、インターネット上の膨大なデータをリアルタイムで収集、予測、分類するなどして提供するサービスが活発になり、様々な分野で複数のデータベースをレコード単位で統合するためのデータリンケージ（Data linkage）の手法が発達している。このうち、行列形式で格納されているデータのリンケージをマイクロデータ構造化と呼ぶ。これには、複数のデータベースに含まれる同一のレコード（調査客体）をマッチングさせるものと、同一でなくとも類似するレコードをマッチングさせるものがある（Rässler, 2002; D'Orazio et al., 2006; 星野, 2009）。本研究は、特に個別性が高い大企業を対象としていることから、複数のデータベースに含まれる同一企業を統合するために、統計的マッチング手法の精度を向上させる方法を検討する。また、大企業のうち上場企業データのみを用いることから生じる母集団からの偏りについては検討の対象から除外する。

## 統計的データマッチングの手法

企業のマイクロデータ構造化に用いることができる統計的データマッチングの主な手法として、下記5つが挙げられる。

### 1) 完全照合

名称、所在地などの文字情報に基づいて完全照合 (Exact matching) によりリンケージしたデータを作成する。完全照合に基づく分析について、美添 (2005), Herzog et al. (2007), Christen (2012), Harron et al. (2015) 等がサーベイしている。しかし、データの突合作業の負担が大きいため、自動化するための方法が検討されてきた。

### 2) Fellegi-Sunter モデル

完全照合を自動的に行う手法で、マッチングさせる複数のデータベースのレコードの全組み合わせについて、マッチング確率に基づいてマッチングする集合とマッチングしない集合のどちらかに分類する (Fellegi and Sunter, 1969)。文字情報に関して、あるレコードの組合せに特定のパターンが生じた場合に、異なる2つのレコードに対してそのようなパターンが生じる確率、及び同一のレコードに対してそのようなパターンが生じる確率の比  $R$  を計算し、 $R$  があらかじめ定めた下限より低い (上限より高い) 値をとる場合、そのレコードの組合せについて、2つのレコードは異なる (同一である) と判定する。各パターンに対するパラメータの推定は、正しいマッチングペアが判明している学習用データを用いて行うが、Jaro (1989) が、学習用データがない場合でも適用可能な EM アルゴリズムに基づく方法を提案して利用が広がった。現在は文字情報に基づく確率的マッチングの代表的な方法として、 $R$  の RecordLinkage やこれを EM アルゴリズムに基づいて改良した fastLink が存在する。

### 3) 欠測値補完に基づく方法

データに多変量正規分布を仮定した上で、マッチングさせる複数のデータベースで共通して存在する変数以外の変数を欠測値とみなし、これらを重回帰モデルや、ベイズ統計学の枠組みに基づいて推測する (Rässler, 2002; D'Orazio et al., 2006; Gilula et al., 2006)。



#### 4) 傾向スコアに基づく方法

マッチングを行うデータ間の距離を、傾向スコア (Propensity score) という、レコードの特徴を縮約した 1 変数の値で計算して、傾向スコアの値が近いレコード同士をマッチングする (Rosenbaum and Rubin, 1983; Rubin, 1986; 星野, 2009; Stuart, 2010)。傾向スコアとは、無作為割り当てが難しく、様々な交絡が生じやすい観察研究において、従属変数と独立変数のどちらにも関連のある共変量と呼ばれる変数を統制するために、複数の共変量を 1 つにまとめて得点化した変数である。

#### 5) レコード間の距離に基づく方法 (最近傍マッチング)

マッチングさせる複数のデータベースのレコードの全組み合わせについて、レコード間の距離を測り、距離が小さいものをマッチングさせる (Rässler, 2002; D'Orazio et al., 2006)。

本研究では 2 種類のデータリンケージを行う。一つは、第 2 章と第 3 章で分析に用いるデータを作成するために行う完全照合によるデータリンケージで、もう一つは、第 4 章で行う多項ロジットモデルに基づくデータリンケージである。第 4 章で行うデータリンケージは、Takabe and Yamashita (2020) が企業データの統計的リンケージ手法として提案した手法で、完全照合によって学習データを作成し、学習データから多項ロジットモデルに基づいてレコード間の距離のウェイトを推定してテストデータのレコード間の距離に乘じ、テストデータのマッチング確率を算出してマッチングするものである。

## 1.4 本論文の構成

本論文の構成について述べる。

第 2 章では、完全照合によって民間データの複数のデータをリンケージさせて、金融政策が企業と銀行の取引関係にどのような影響を与えたかを統計的因果推論の枠組みで分析する。完全照合によってリンケージさせたデータは、企業の財務データと、銀行の財務データと、企業がどの銀行からいくら借りているかを表す金融機関別借入金データである。これらをリンケージさせることによって、企業と銀行の取引関係を分析

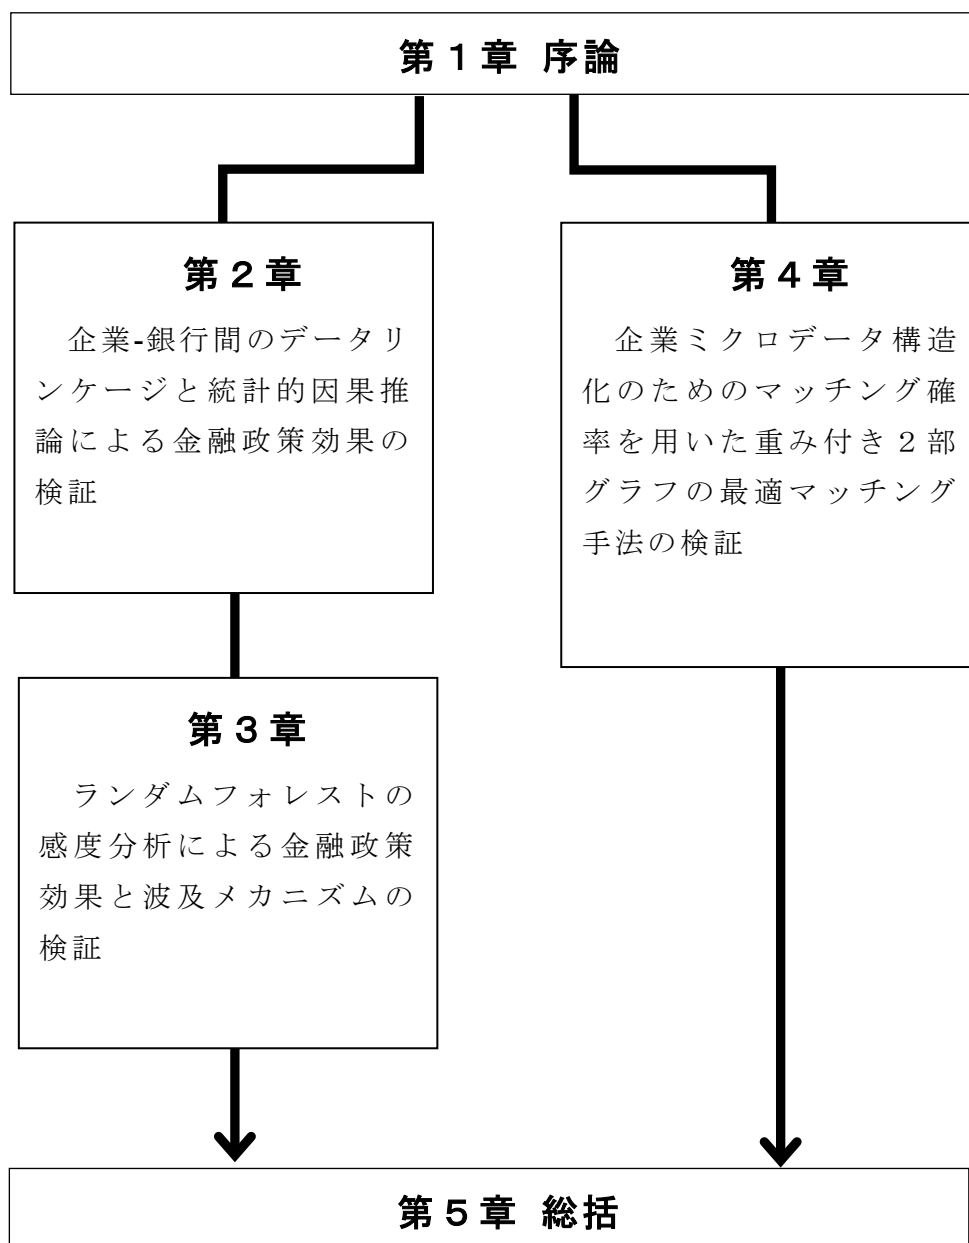
の対象とすることができる。また、金融政策について、緩和、引き締め、中立の別に実施を表す離散変数を作成して用いた。分析手法としては、統計的因果推論の枠組みで、観測データに基づく平均処置効果の推定を行った。企業の借入を被説明変数とした従来のパネル回帰分析が、操作変数として大多数のダミー変数を導入していたのに対して、本分析では、操作変数（共変量）の影響を取り除くために、機械学習の手法の一つであるランダムフォレストで推計する傾向スコアを用いた。これによって、回帰分析が避けることができないモデルの誤設定に伴う偏りを回避している。

第3章では、第2章でリンケージさせたデータを用いつつ、企業の借入前年比が増加するか否かを示す離散変数を被説明変数として、よりアルゴリズムの特性を生かして、データ適合的にランダムフォレストアルゴリズムを適用し、金融政策の実施に対する感度分析を行った。感度分析には、金融政策単独の影響を見るための **Partial Dependence Plot** と、金融政策とその他変数の交互作用を表す **Accumulated Local Effects Plot** を用いた。

第4章では、政策立案の立場からのより具体的な関心に答える分析を可能にするために、企業のマイクロデータ構造化を進めることを目的として、Takabe and Yamashita (2020) が提案した多項ロジットモデルを用いた統計的マッチング手法の精度を向上させる方法を検討する。同手法を新たなデータに適用し、この手法が広く企業データに適用できるか、安定性を検証するとともに、利用する変数の内容に工夫を加えることで、マッチング精度が向上することを実証する。また、マッチング確率を用いた重み付き2部グラフの最適化マッチングアルゴリズムを、目的関数と制約条件に着目して比較検討して、より精度を向上させるアルゴリズムを検証する。

第5章は、第2章、第3章、第4章で行った分析の結果を基に、本研究によって得られた成果の総括及び全体的な考察を行うとともに、将来の展望を示す。本論文の構成（各章の関係）について図示したのが、図表1である。

図表 1 本論文の構成



なお、本博士論文の中核をなす第2章と第3章と第4章の内容については、以下の論文とリサーチメモランダムに基づいている。

第2章, 第3章

園田桂子, 山下智志 (2021) . 企業-銀行間のデータ結合と機械学習による金融政策効果と波及メカニズムの検証, 統計数理, 69 巻 2 号, 367-388 頁.

第4章

Sonoda, K., Takabe, I., and Yamashita, S. (2023). Statistical Matching Methods for Company Data using Multinomial Logit Models and Combinatorial Optimization (submitted).

Sonoda, K., Takabe, I., and Yamashita, S. (2023). Combinatorial Optimization for Company Data in Statistical Matching using Multinomial Logit Models, *Research Memorandum*, No.1223.

## 第2章

# 企業-銀行間のデータリンケージと 統計的因果推論による金融政策効果 の検証

### 2.1 導入

第1章で述べたように、金融政策効果の実証分析はマクロ的な視点からのみ取り扱われることが多かった。しかし、特に2008年のリーマンショック時に、経済主体が連鎖的にショックを受けてからは、ミクロとマクロのつながりへの関心が高まり、政策立案の立場でも、金融政策がどのような経路で経済主体の間に波及しているのか、ミクロデータに基づく実証研究が求められるようになった。図表2は、日本銀行が想定している、金融政策が波及するメカニズムである。ミクロデータに基づく分析で問題となるのが、分析に用いることができるデータの不足である。金融機関や企業といった経済主体それぞれに関する財務データはあっても、金融政策の影響を受けて、金融機関と企業の取引に動的にどのように影響したかを知るためには、複数のデータベースをリンケージさせて分析に有用なデータを構築する必要がある。

第2章では、異なる経済主体のデータを照合キーに基づく完全照合でリンケージさせて、分析に有用なデータを構築する。リンケージに使用したデータは、日経 NEEDS 社の FinancialQUEST が提供している、企業の財務データベース、銀行の財務データベース、企業がどの銀行からいくら借り入れているかを格納した金融機関別借入金データベースの3つのデータベースである。このデータは、日経 NEEDS 社が有価証券報告書等の公表情報と独自のアンケート調査から作成して、有償で提供しているもので、調査対象は主に上場企業に限られる。

データを用いたモデリング同定には2つの方法があり、一つは、デー

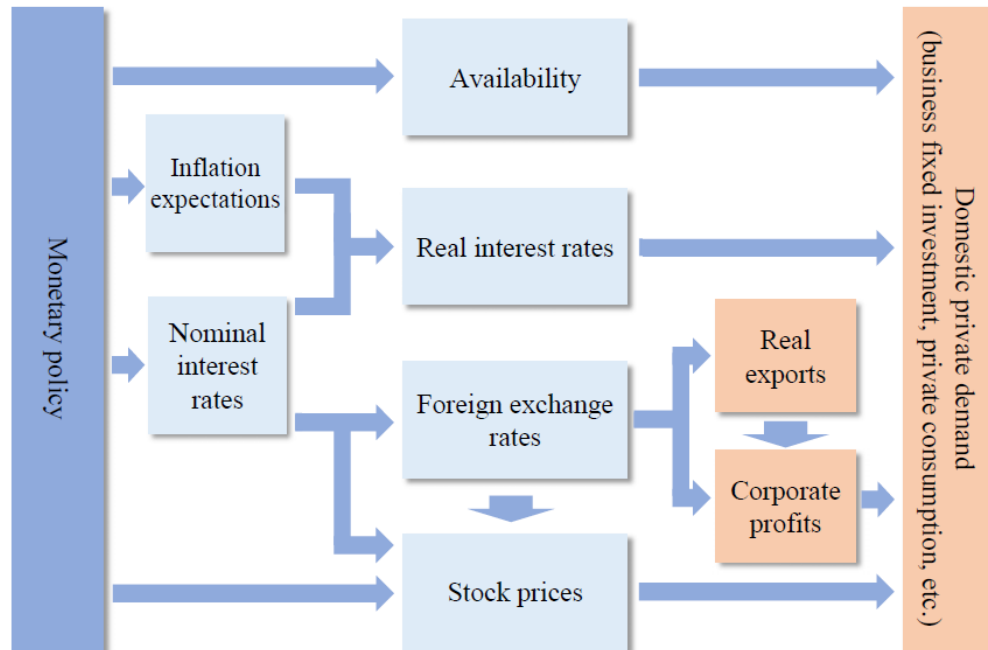
タが確率的モデルに基づいて生成されたと仮定するのに対して、もう一つは、データ生成の構造は未知のまま、アルゴリズムを用いるものと言われる (Brieman, 2001b)。分析手法に関して、経済分野はほとんど前者に注力してきた (Athey et al., 2017)。金融政策の効果に関する数少ないマイクロデータに基づく分析も、前者の流れを汲む、パネル回帰分析が行われてきた。しかし、これらは少数の説明変数と、評価と解釈がしにくい多数のダミー変数を導入しており、回帰式において、他の説明変数が担うべき要因をダミー変数に説明させている可能性がある。本章では、金融政策の効果を検証するために、統計的因果推論を行う。統計的因果推論とは、共変量という、被説明変数と説明変数のどちらにも関連する変数の影響を除去して、両者の相関関係を明らかにするものである。共変量を統制するために、傾向スコアの推定を行うが、この推定において、機械学習の一つであるランダムフォレスト回帰を用いて、特に、説明変数や交絡因子の選定、モデルの定式化の誤りに起因する推定値の偏りを避ける。

### 統計的因果推論の分析

本分析では、企業の借入前年比を連続変数のまま被説明変数に、金融政策変数を離散変数として説明変数に用いて、ルービンの因果効果における平均処置効果を推定した。この際、銀行と企業の財務変数やマクロ経済変数が企業の借入前年比に影響を与える一方、金融政策の介入／不介入にも影響する構造がある、すなわち、銀行と企業の財務変数やマクロ経済変数が共変量であると考えた。統計的因果推論の枠組みを用いたのは、銀行と企業の財務変数やマクロ経済変数の影響が取り除かれた時に、金融政策の介入／不介入が平均処置効果に影響を及ぼし得るか否かを平均処置効果の値で明らかにすることで、経済分野において金融政策の波及経路と想定されている、銀行や企業のバランスシートを通じた波及が、過去に存在したか否かを検証するためである。平均処置効果の推定にあたっては、モデルの誤設定に対してロバストな **Double Machine Learning (DML)** (Chernozhukov et al., 2017, 2018) と呼ばれる手法を用いた。この結果、1982年から2016年度までについては、銀行のバランスシートを通じた金融政策の介入効果については明らかでないものの、企業のバランスシートを通じた金融政策の介入効果があることが示唆された。但し、その影響度合いは大きくないことがわかった。

図表 2 金融政策の主なトランスミッションメカニズム

銀行と企業のバランスシートに現れると想定されている。



(出所) Kuroda(2021)に著者補記。

## 2.2 先行研究と課題

### 2.2.1 パネル回帰分析による先行研究と課題

マイクロデータを用いた先行研究の多くはパネル回帰分析によるものである。海外については、Jiménez et al. (2012, 2014), Dell’Ariccia et al. (2017). 日本については、Hosono and Miyakawa (2014), Ono et al. (2016), Nakashima et al. (2017) 等がある。これらの先行研究は、ある企業がどの銀行からいくら借りているかを調査した、銀行と企業のマッチ・レベル・データ（ローン・レベル・データとも呼ばれる）を用いて、借入額（もしくはその前年比）を説明するモデルを構築し、時間的に先行する金融政策を表す変数の係数が、 $p$ 値で見て有意であれば政策効果があるとしている。経済理論では、金融政策は銀行のバランスシートと、企業のバランスシートの両方を通じて波及すると言われていることから、説明変数には銀行と企業の財務変数も用いて、銀行の供給要因と企業の需要とを区

別する。しかし、これら説明変数の数は、Jiménez et al. (2014) では 16, Nakashima et al. (2017) は 25, Hosono and Miyakawa (2014) は 15, Ono et al. (2016) は 18 系列と、被説明変数のサンプルサイズが 10 万以上あるのに対して少なく、代わって、時間の数に企業数や銀行数を乗じた多くのダミー変数を入れている。しかし、これらダミー変数は評価と解釈ができず、パラメータの推計にあたって、他の説明変数が本来担うべき要因をダミー変数に説明させている可能性がある。回帰関数の誤設定を避けるために、モデルを事前に指定する必要がなく、関数の形状も柔軟に設定できるカーネル回帰分析を始めとする局所多項式回帰モデルを用いることがあるが (Jiménez et al., 2014), 計算コストが高く、説明変数として取り込むことができる数が限られている。

## 2.2.2 機械学習を適用した先行研究と課題

近年は、何らかの問題を解決することを目標とするならば、より多様なツールを採用する必要があるとして、金融分野でも、特に予測を行う場面で、機械学習の手法を適用する試みが進んでいる。例えば、Peer to Peer (P2P) Lending と呼ばれる個人間の貸出 (Zhou et al., 2019; Malekipirbazari and Aksakalli, 2015), クレジットカード決済 (Butaru et al., 2016), 銀行貸出におけるデフォルト時損失率の推定 (Hurlin et al., 2018), 金融監督の観点から銀行の倒産リスクを計測する場面 (Beutel et al., 2019; Suss and Treitel, 2019; Petropoulos et al., 2020), 国際的な金融監督の観点から国別の金融危機発生リスクを計測する場面 (Alessi and Detken, 2018) でも同様の試みがなされている。その結果、先行研究で多く用いられてきた線形回帰分析と比較して、データ適合的なモデル探索を体系的に行う機械学習の方が高い予測精度を達成していることから、分析者によるモデルの誤設定を避けながら、効率的に計算できて、予測精度も高いとして、機械学習を取り入れる方法が進展している (Kleinberg et al., 2015; Athey and Imbens, 2017; Athey, 2018)。

単に予測を行うのではなく、政策立案に資する情報を得る目的でアルゴリズムを効果的に適用するためには、問題の構造を利用する必要がある。すなわち、推定対象の因果性や、変数の内生性、すなわち、例えば本来なら政策変数がショックの始点であるべきだが、システム内の別の要因や変数によって影響を受ける変数であること等を、分析の枠組みや、パネルデータの構造、アルゴリズムを適用する上でのチューニングに加える必要がある。従って、データ生成の構造を未知のまま置いておくと



しても、これらについて、その分野に関する知識に基づいた適切な仮定を置く必要がある。

### 2.2.3 統計的因果推論による方法と課題

実験条件への割り当てが無作為に行われた実験データではなく、実社会の観測データから介入効果を検証するために、統計的因果推論が様々な分野で取り入れられている。この手法は、変数間の関係に関する背景情報を積極的に取り入れて偏りを修正することと、推定を行う際に、線形モデルのようなパラメトリックな方法とカーネル法のようなノンパラメトリックな方法の中間の形態であるセミパラメトリックな方法を使うことを特徴としている(星野, 2009)。統計的因果推論は、共変量という、被説明変数と説明変数のどちらにも関連する変数の影響を除去して、両者の相関関係を明確にするものである。従って、指定した共変量に関して疑似相関は除去していると考えられる。一方で、相関関係を明確にするものであって直接因果関係を推定するものではない。しかし、金融政策に効果がなければ相関関係も見いだせないことから、分析を行う意味がある。この手法をマイクロデータに基づく金融政策効果の実証分析に用いた先行研究は、調査した限りみつからない。

統計的因果推論の枠組みは、偏りを修正するための情報として、政策介入を受けたグループと、受けていないグループのデータが実測されていることを前提としている。しかし、金融政策のように、物価や経済活動を安定させるために随時発動し、経済主体に広く影響を及ぼすような政策は、介入している時と、景気に中立的で介入していない時をデータ上区別することが難しく、判断が必要となる。

## 2.3 完全照合によるデータリンケージ

### 2.3.1 元となるデータの属性

分析のために、日経 NEEDS 社が有償で提供している FinancialQUEST の3つのデータベースを完全照合によってリンケージした。使用したデータベースの一つ目は、銀行と企業間の取引関係を示す「金融機関別借入金データベース」(①企業-銀行間取引データベース)である。これ

は、企業に対して、決算月時点でどの銀行からいくら借りているかを調査したデータである。また、同社の財務（短信・有報）データベースの「財務データ」及び「財務指標データ」から、②企業財務データベースと、③銀行財務データベースを取得した。


データ期間は、1982～2016年度の35年、企業のセグメントは全国証券取引所上場企業（銀行、保険を除く）、銀行のセグメントは都市銀行と地方銀行である。

### 2.3.2 2次元配列へのデータリンケージ

本項では、前項で述べた①～③の3つのデータベースと、④マクロ経済データ、⑤金融政策データをリンケージさせて、2次元配列のデータベースを作る過程を説明する。元となる5つのデータベースのうち、①、②、③は3次元配列で、④、⑤は行列である。まず、①企業－銀行間取引データに対して、②企業財務データを企業の固有IDを照合キーとしてリンケージし、③銀行財務データを銀行の固有IDを照合キーとしてリンケージする。④マクロ経済データと⑤金融政策データは、①、②、③のデータの年度に応じてリンケージさせる。

図表3の通り、①企業－銀行間取引データベース $\mathbf{Y}$ は、企業 $c(1, \dots, n_c) \times$ 銀行 $b(1, \dots, n_b) \times$ 年度 $t(1, \dots, n_t)$ から成る3次元配列で、各要素は、企業 $c$ の、銀行 $b$ からの、年度 $t$ における借入前年比 $y_{c,b,t}$ である。②企業財務データベース $\mathbf{C}$ は、企業 $c(1, \dots, n_c) \times$ 企業の財務変数 $f(1, \dots, n_f) \times$ 年度 $t(1, \dots, n_t)$ から成る3次元配列で、各要素は、企業 $c$ の財務変数 $f$ の $t$ 年度の値 $x_{c,f,t}^C$ である。③銀行財務データベース $\mathbf{B}$ は、銀行 $b(1, \dots, n_b) \times$ 銀行の財務変数 $s(1, \dots, n_s) \times$ 年度 $t(1, \dots, n_t)$ から成る3次元配列で、各要素は、銀行 $b$ の財務変数 $s$ の $t$ 年度の値 $x_{b,s,t}^B$ である。④マクロ経済データ $\mathbf{Q}$ は、マクロ経済変数 $q(1, \dots, n_q) \times$ 年度 $t(1, \dots, n_t)$ から成る行列で、各要素は、マクロ経済変数 $q$ の $t$ 年度の値 $x_{q,t}^Q$ である。⑤金融政策データ $\mathbf{Z}$ は、金融政策変数 $z(1, \dots, n_z) \times$ 年度 $t(1, \dots, n_t)$ から成る行列で、各要素は、金融政策変数 $z$ の $t$ 年度の値 $x_{z,t}^Z$ である。

図表 3 データのリンケージ方法



分析対象とするデータベース(Y\_X)

企業-銀行間取引(1変数) + 企業財務(167変数) + 銀行財務(8変数)  
+ マクロ経済(2変数) + 金融政策(4変数) = 182列

企業ID	銀行ID	年度	借入前年比	企業財務変数1	...	銀行財務変数1	...	マクロ経済変数1	...	金融政策変数1	...
1	1	1990									
1	1	1991									
1	2	1992									
1	2	1993									
2	15	2000									
2	80	2000									
3	26	2001									
3	101	2002									
4	101	2001									
⋮	⋮	⋮									
1869	145	2016									

348,382行 × 182列

データ数n = 企業数(n<sub>c</sub>) × 銀行数(n<sub>b</sub>) × 年度の数(n<sub>t</sub>)  
(各行がデータインスタンス i)

3次元配列である①～③を2次元配列にした上で①～⑤全てをリンケージさせて分析用データベース $\mathbf{Y}_X$ を作る．まず，①の全ての $y_{c,b,t}$ に，番号 $i(1, \dots, n|n = n_c \times n_b \times n_t)$ を振って行方向に積み上げ，行の数が $n$ ，列の数が1（借入前年比）のパネルデータによるベクトル $\mathbf{y}$ にする． $\mathbf{y}$ の中身は下記のような並びになっている．

$$(2.1) \quad \mathbf{Y} = \begin{bmatrix} y_{1,1} & \cdots & y_{1,n_b} \\ \vdots & \ddots & \vdots \\ y_{n_c,1} & \cdots & y_{n_c,n_b} \end{bmatrix}_t, \quad t(1, \dots, n_t)$$

$$(2.2) \quad \mathbf{y} = \text{vec}(\mathbf{Y}_{c,b,t}) = \begin{bmatrix} \{(y_{1,1,1}, \dots, y_{1,n_b,1}), (y_{1,1,2}, \dots, y_{1,n_b,2}), \dots, (y_{1,1,n_t}, \dots, y_{1,n_b,n_t})\}, \\ \{(y_{2,1,1}, \dots, y_{2,n_b,1}), (y_{2,1,2}, \dots, y_{2,n_b,2}), \dots, (y_{2,1,n_t}, \dots, y_{2,n_b,n_t})\}, \\ \vdots \\ \{(y_{n_c,1,1}, \dots, y_{n_c,n_b,1}), (y_{n_c,1,2}, \dots, y_{n_c,n_b,2}), \dots, (y_{n_c,1,n_t}, \dots, y_{n_c,n_b,n_t})\} \end{bmatrix}^T$$

3次元配列である② $\mathbf{C}$ と③ $\mathbf{B}$ についても2次元配列にする．②企業財務データベース $\mathbf{C}$ は変数 $f$ 別に，要素 $x_{c,f,t}^C$ を，企業及び年度について行方向に積み上げてベクトル化する．

$$(2.3) \quad \mathbf{x}_f = \text{vec}(x_f) = [(x_{1,f,1}, \dots, x_{1,f,n_t}), (x_{2,f,1}, \dots, x_{2,f,n_t}), \dots, (x_{n_c,f,1}, \dots, x_{n_c,f,n_t})]^T$$

こうして作成した $\mathbf{x}_f$ を列方向に並べることで， $n_c \times n_t$ 行 $n_f$ 列の行列にする．この行列が， $n_b$ 個存在しており，被説明変数のデータ数である $n$ 行 $n_f$ 列の行列となる．

③銀行財務データベース $\mathbf{B}$ も同様に，変数 $s$ 別に，要素 $x_{b,s,t}^B$ を，銀行及び年度について行方向に積み上げてベクトル化する．

$$(2.4) \quad \mathbf{x}_s = \text{vec}(x_s) = [(x_{1,s,1}, \dots, x_{1,s,n_t}), (x_{2,s,1}, \dots, x_{2,s,n_t}), \dots, (x_{n_b,s,1}, \dots, x_{n_b,s,n_t})]^T$$

こうして作成した $\mathbf{x}_s$ を列方向に並べることで、 $n_b \times n_t$ 行 $n_s$ 列の行列にする。この行列が $n_c$ 個存在しており、 $n$ 行 $n_s$ 列の行列となる。

④マクロ経済データ $\mathbf{Q}$ は、 $n_t$ 行 $n_q$ 列の行列で、この行列が $n_c \times n_b$ 個存在しており、 $n$ 行 $n_q$ 列の行列となる。⑤金融政策データ $\mathbf{Z}$ は、 $n_t$ 行 $n_z$ 列の行列で、この行列が $n_c \times n_b$ 個存在しており、 $n$ 行 $n_z$ 列の行列となる。

こうして行列化した5つのデータベースを、列方向に並べたのが、分析データ $\mathbf{Y}_X$ である(図表3)。このうち、 $\mathbf{y}$ を除いたものを説明変数行列 $\mathbf{X}$ と呼ぶことにする。なお、5つのデータベースは、時間軸を年度で統一し、説明変数となる②~⑤の4つのデータベースは被説明変数①の1年度前の値を要素とした。

### 2.3.3 変数選択と欠損値への対応

$\mathbf{Y}_X$ は、例えば $\mathbf{y}$ において、ある銀行とある企業の間継続した取引がない、といったことが日常的に生じていることから欠損値が非常に多い。本研究では、欠損値が持つ情報(なぜこの銀行がこの企業と取引していないのか等)には関心がなく、欠損値の存在が分析上のデメリットになることから、 $\mathbf{Y}_X$ から欠損値を含む行を削除して、擬似的に完全データを作り出した(リストワイズ除去)。この結果、 $\mathbf{Y}_X$ は、348,382取引件数(行)×181変数(列)から成るデータとなった。

これにあたって、できるだけ多くの変数を使用しつつ、一部の変数の欠損値によるデータの削除を最小限に抑えるために、相対的に欠損値が多い企業財務データについて、変数毎に欠損値の発生割合を計測し、欠損値がデータ行の2割以上を占める変数を元となるデータベース $\mathbf{C}$ から除外している。また、相対的に欠損値が少ない銀行財務データについても、分析上注目に値しないと考えられる変数をデータベース $\mathbf{B}$ から除外している。

### 2.3.4 外れ値への対応と変数変換の適用

データをリンケージした後、下記のようなデータ加工を行った。

## 外れ値への対応

財務データについては、大きさの順にソートし、上位1%以上、または下位1%以下の値については、それぞれ上位1%における値、下位1%における値に置換えた。

## 変数変換の適用

全ての変数について対数変換又は `neglog` 変換（森平，2009；山下・三浦，2011）を適用した後、0から1の範囲に収まるように線形変換を行った。これは、例えば、金融政策変数として用いているコールレートや日銀当座預金等は、政策導入時は小さく変動させて効果を観察し、効果が不足していると段々と大きく変動させる傾向があるなど、対数変換によって、相対的に低い水準を強調することがより適切と考えられるためである。また、分析で用いるランダムフォレストでは、分割対象となるノードの数が増えるほど変数の重要度が相対的に増加する。このため、数値変数の中でも取り得る有効数字の桁数が大きい方が、分割のための閾値を数多くとることができるため、木が深くなるごとに重要度が相対的に高く出る傾向がある。この傾向へ対処する目的がある。

## 図表 4 変数一覧

マクロ経済環境	
(1) 実質GDP成長率	○
(2) 実質GDP成長率前年度差	○
金融政策	
(1) コールレート	
(2) コールレート前年度差	
(3) 日銀当座預金	
(4) 日銀当座預金前年度差	
銀行の財務指標	
(1) 預貸率	○
(2) 預証率	○
(3) LN(総資産)	○
(4) 経常利益/総資産	○
(5) 国債/総資産	○
(6) 地方債/総資産	○
(7) 純資産/総資産	○
(8) (現金+預金+コール市場貸出+売買目的有価証券+国債+地方債-日銀預け金)/総資産	○
企業の財務指標	
一株当たり指標	
(1) 1株当たり売上高	
(2) 1株当たり事業利益	
(3) 1株当利払後事業利益	
(4) 1株当たり営業利益	
(5) 1株当たり経常利益	
(6) 1株当たり税引前利益	
(7) 1株当たり利益	
(8) 1株当たりEBIT ((経常利益+支払利息・割引料)÷期中平均株式数×1000000)	
(9) 1株当たりEBITDA ((経常利益+支払利息・割引料+減価償却実施額)÷期中平均株式数×1000000)	
(10) 1株当たり簡易版キャッシュフロー (簡易版キャッシュフロー(B)÷期中平均株式数×1000000)	
(11) 1株当たり純資産 (資本合計÷期末発行済株式総数×1000000)	
(12) 1株当たり純資産 (広義の自己資本÷期末発行済株式総数×1000000)	
その他指標	
(13) 資本市場調達・借入比率	○
(14) 海外売上高比率 (3ヵ月会計期間)前期差	
収益性	
(15) 企業利潤率	
(16) 自己資本営業利益率	○
(17) 自己資本利払後事業利益率	
(18) 自己資本経常利益率	
(19) 固定資産回転率	
(20) 有形固定資産回転率	
(21) 有形固定資産回転率-取得価格基準	
(22) 流動資産回転日数	○
(23) 売上債権回転日数	○
(24) 買入債務回転日数	
(25) 棚卸資産回転日数	
(26) 商品・製品回転日数	
(27) 半製品・仕掛品回転日数	

- (28) 原材料・その他回転日数  
(29) 売上高原価率  
(30) 売上高販管費率  
(31) 売上高減価償却費率 (減価償却実施額 ÷ 売上高・営業収益 × 100)  
(32) 売上高純金利負担率 ○  
(33) 売上高支払利息割引料率 ○  
(34) 売上高設備投資比率 ((有形固定資産合計 - 有形固定資産合計前期値 + 減価償却実施額 + 減損損失) ÷ 売上高・営業収益 × 100)  
(35) 償却前内部留保率  
(36) 投融資利回り  
(37) 純資産回転率 ○  
(38) 純利益率  
(39) 長期負債對自己資本比率 ○  
(40) 自己資本営業利益率前期差  
(41) 自己資本利払後事業利益率前期差  
(42) 自己資本経常利益率前期差  
(43) 売上高原価率前期差  
(44) 売上高販管費率前期差  
(45) 売上高減価償却費率 (減価償却実施額 ÷ 売上高・営業収益 × 100)前期差  
(46) 売上高純金利負担率前期差  
(47) 売上高支払利息割引料率前期差  
(48) 売上高設備投資比率 ((有形固定資産合計 - 有形固定資産合計前期値 + 減価償却実施額 + 減損損失) ÷ 売上高・営業収益 × 100)前期差  
(49) 償却前内部留保率前期差  
(50) 純利益率前期差  
(51) 長期負債對自己資本比率前期差
- 
- 資本利益率指標
- (52) 使用総資本総利益率  
(53) 使用総資本事業利益率  
(54) 使用総資本事業利益率 - 利払後  
(55) 使用総資本営業利益率  
(56) 使用総資本経常利益率  
(57) 使用総資本税引前利益率  
(58) 使用総資本利益率  
(59) 投資収益率・ROI ((営業利益 + 受取利息・配当金) ÷ (資産合計前期値 - 流動資産合計前期値 - 流動負債合計前期値)) × 100  
(60) 投下資本収益率・ROIC ((営業利益 + 受取利息・配当金) ÷ (資本合計前期値 + 短期借入金前期値 + 役員・従業員短期借入金 + コマーシャルペーパー前期値 + 1年内返済の長期借入金前期値 + 1年内償還の社債・転換社債前期値 + 従業員預り金前期値 + 社債・転換社債前期値 + 長期借入金前期値 + 受取手形割引高前期値 - 現金・預金前期値 + 有価証券前期値 + 営業貸付金・営業投資有価証券前期値) × 100)  
マージン関連
- 
- (61) 売上高総利益率  
(62) 売上高事業利益率  
(63) 売上高事業利益率 - 利払後  
(64) 売上高営業利益率  
(65) 売上高経常利益率  
(66) 売上高EBIT比率 ((経常利益 + 支払利息・割引料) ÷ 売上高・営業収益 × 100)  
(67) 売上高EBITDA比率 ((経常利益 + 支払利息・割引料 + 減価償却実施額) ÷ 売上高・営業収益 × 100)  
(68) 売上高総利益率前期差  
(69) 売上高事業利益率前期差  
(70) 売上高事業利益率 - 利払後前期差  
(71) 売上高営業利益率前期差  
(72) 売上高経常利益率前期差  
(73) 売上高EBIT比率 ((経常利益 + 支払利息・割引料) ÷ 売上高・営業収益 × 100)前期差  
(74) 売上高EBITDA比率 ((経常利益 + 支払利息・割引料 + 減価償却実施額) ÷ 売上高・営業収益 × 100)前期差



## 安全性

(75)	手元流動性比率	
(76)	支払準備率	
(77)	預借率	○
(78)	現金・預金対有利子負債比率	○
(79)	当座比率	○
(80)	流動比率	○
(81)	正味運転資本額	
(82)	純運転資本額	○
(83)	正味運転資本比率	○
(84)	売上債権対買入債務比率	
(85)	棚卸資産対買入債務比率	
(86)	受取手形割引高回転日数	
(87)	固定負債対有形固定資産比率 (固定負債合計÷有形固定資産合計×100)	
(88)	固定負債対有形固定資産比率 ((固定負債合計+正味運転資本額)÷有形固定資産合計×100)	
(89)	固定比率	
(90)	固定長期適合率	○
(91)	自己資本比率 (資本合計÷負債・純資産合計×100)	○
(92)	自己資本比率 (広義の自己資本÷負債・純資産合計×100)	○
(93)	負債比率	○
(94)	有利子負債額	
(95)	純有利子負債額	
(96)	有利子負債対自己資本比率	○
(97)	純有利子負債対自己資本比率	○
(98)	借入金依存度	○
(99)	自己金融比率	
(100)	有利子負債利率	
(101)	インタレスト・カバレッジ ((営業利益+受取利息・割引料・有価証券利息)÷支払利息・割引料)	
(102)	インタレスト・カバレッジ (税引前当期純利益+支払利息・割引料)÷支払利息・割引料)	
(103)	減価償却率	○
(104)	有形固定資産減価償却累計率	
(105)	手元流動性比率前期差	○
(106)	支払準備率前期差	
(107)	預借率前期差	
(108)	現金・預金対有利子負債比率前期差	
(109)	当座比率前期差	
(110)	流動比率前期差	
(111)	正味運転資本額前期差	○
(112)	純運転資本額前期差	
(113)	正味運転資本比率前期差	
(114)	売上債権対買入債務比率前期差	
(115)	棚卸資産対買入債務比率前期差	
(116)	固定負債対有形固定資産比率 (固定負債合計÷有形固定資産合計×100)前期差	
(117)	固定負債対有形固定資産比率 ((固定負債合計+正味運転資本額)÷有形固定資産合計×100)前期差	
(118)	固定比率前期差	○
(119)	固定長期適合率前期差	
(120)	自己資本比率 (資本合計÷負債・純資産合計×100)前期差	
(121)	自己資本比率 (広義の自己資本÷負債・純資産合計×100)前期差	
(122)	負債比率前期差	
(123)	有利子負債額前期差	○
(124)	純有利子負債額前期差	○
(125)	有利子負債対自己資本比率前期差	
(126)	純有利子負債対自己資本比率前期差	
(127)	借入金依存度前期差	
(128)	有利子負債利率前期差	
(129)	インタレスト・カバレッジ ((営業利益+受取利息・割引料・有価証券利息)÷支払利息・割引料)前期差	
(130)	インタレスト・カバレッジ (税引前当期純利益+支払利息・割引料)÷支払利息・割引料)前期差	
(131)	減価償却率前期差	
(132)	有形固定資産減価償却累計率前期差	○

## 成長性

(133)	増収率(前年同期比)	○
(134)	自己資本成長率(前年同期比) キャッシュフロー関連	
(135)	簡易版キャッシュフロー(B)	○
(136)	EBIT 経常利益+支払利息・割引料	○
(137)	EBITDA経常利益+支払利息・割引料+減価償却実施額	○
(138)	経常収支	○
(139)	経常収支比率	
(140)	簡易版キャッシュフロー(A) 前期差	
(141)	株主向けキャッシュフロー(フリーキャッシュフロー+短期借入金による収入+コマーシャルペーパーによる調達額+長期借入金による収入+社債の発行による収入+短期借入金の返済による支出+ファイナンスの債務の返済+コマーシャルペーパー返済額+長期借入金の返済による支出+社債の償還による支出)前期差	
(142)	EBITDA経常利益+支払利息・割引料+減価償却費 前期差	
(143)	EBITDA経常利益+支払利息・割引料+減価償却実施額 前期差	
(144)	経常収支前期差	
(145)	簡易版キャッシュフロー(B)対負債比率	
(146)	簡易版キャッシュフロー(B)対固定負債比率	
(147)	簡易版キャッシュフロー(B)対流動負債比率	
(148)	簡易版キャッシュフロー(B)対長期負債残高比率	○
(149)	簡易版キャッシュフロー(B)対有利子負債比率	
(150)	インタレストカバレッジ・キャッシュフロー((簡易版キャッシュフロー(B)+支払利息・割引料+法人税・住民税および事業税合計)÷支払利息・割引料)	
(151)	簡易版キャッシュフロー(B)対設備投資比率簡易版CF÷[有形固定資産合計-有形固定資産合計前期値+減価償却実施額+減損損失]×100	
(152)	簡易版キャッシュフロー(B)対売上高比率	
(153)	簡易版キャッシュフロー(B)対負債比率前期差	
(154)	簡易版キャッシュフロー(B)対固定負債比率前期差	
(155)	簡易版キャッシュフロー(B)対流動負債比率前期差	
(156)	簡易版キャッシュフロー(B)対長期負債残高比率前期差	
(157)	簡易版キャッシュフロー(B)対有利子負債比率前期差	
(158)	インタレストカバレッジ・キャッシュフロー((簡易版キャッシュフロー(B)+支払利息・割引料+法人税・住民税および事業税合計)÷支払利息・割引料) 前期差	
(159)	簡易版キャッシュフロー(B)対売上高比率前期差	
	ROE関連指標	
(160)	ROE(自己資本利益率)当期利益÷資本合計×100	
(161)	売上高利益率	
(162)	売上高税引前利益率	
(163)	使用総資本回転率	
(164)	財務レバレッジ	○
(165)	ROE(自己資本利益率)((当期利益+その他の包括利益増減額+少数株主損益)÷広義の自己資本×100)	
(166)	税金等負担効果(当期利益÷税引前当期純利益)前期差	
(167)	使用総資本回転率前期差	

(注1) 広義の自己資本＝

資本合計+特別法上の準備金+少数株主持分+為替換算調整額+繰延税金負債+再評価に係る繰延税金負債+新株予約権

簡易版キャッシュフロー(A)＝

税引前当期利益+減価償却実施額+減損損失+流動資産合計前期値-現金・預金前期値-有価証券前期値-営業貸付金・営業投資有価証券前期値-自己株式前期値-流動資産合計-現金・預金-有価証券-営業貸付金・営業投資有価証券-自己株式+流動負債合計-短期借入金-役員・従業員短期借入金-コマーシャルペーパー-1年内返済の長期借入金-1年内償還の社債・転換社債-流動負債合計前期値-短期借入金前期値-役員・従業員短期借入金前期値-コマーシャルペーパー前期値-1年内返済の長期借入金前期値-1年内償還の社債・転換社債前期値

簡易版キャッシュフロー(B)＝

当期利益+減価償却実施額+減損損失-年度中普通株式配当金+年度中優先株式配当金+年度末普通株式配当金+年度末優先株式配当金

(注2) 名称の右端の○は2章の統計的因果推論分析で共変量として用いた変数であることを示す。

## 2.4 ルービンの因果効果による金融政策の波及効果の推定

### 2.4.1 因果効果と推定モデル

本分析では、ルービンの因果効果 (Rubin, 1974) を推定する (以下、因果とはこの意味で用いる)。金融政策による介入を受けたグループ (介入群) の被説明変数の値を  $y^1$ , 介入を受けなかったグループ (非介入群) の被説明変数の値を  $y^0$  とする。実際に介入を受けたグループがもし介入を受けなかった場合と、実際に介入を受けなかったグループがもし介入を受けた場合も反実仮想して、全てのデータについて、2つの潜在的な被説明変数  $y^1, y^0$  が存在すると考える。 $y^1$  と  $y^0$  の差の期待値  $E(y^1 - y^0)$  を因果効果と定義して、全てのデータの  $y^1$  と  $y^0$  の差の平均をその推定値 (平均処置効果) とする (Rosenbaum and Rubin, 1983)。

#### ルービンの因果効果 (平均処置効果)

$$(2.5) \quad \begin{aligned} E(y^1 - y^0) &= E(y^1) - E(y^0) \\ \hat{E}(y^1) &= \frac{1}{n} \sum_{i=1}^n y^1, \quad \hat{E}(y^0) = \frac{1}{n} \sum_{i=1}^n y^0 \end{aligned}$$

実際に観測される被説明変数  $y$  の値は、介入群を  $z = 1$ , 非介入群を  $z = 0$  とする割り当て変数  $z$  と、2つの潜在的な被説明変数を用いて下記のように表される。

$$(2.6) \quad y = zy^1 - (1 - z)y^0$$

### 2.4.2 分析の概要

ルービンの因果効果では、反実仮想によって全てのデータに  $y^1$  と  $y^0$  が存在すると考えるものの、実際には介入群は  $y^0$  が、非介入群は  $y^1$  が、観察されずに欠測している。そこで、観測されているデータのみを用いて因果効果を推定するために、被説明変数と説明変数のどちらにも関連している共変量  $x$  を一つの変数に集約した傾向スコア (Rosenbaum and Rubin,

1983) を用いて、推定の偏りの調整を行う (星野, 2009) .

傾向スコアを用いて因果効果を推定できるための前提条件は、共変量を所与とするときに「強く無視できる割り当て」 (Strongly Ignorable Treatment Assignment) が成り立っていることである。これは、共変量  $x$  の値を条件付けると (共変量の値が同じ対象だけで考える時)、介入群 ( $z = 1$ ) に割り当てられた時の被説明変数  $y^1$  と、非介入群 ( $z = 0$ ) に割り当てられた時の被説明変数  $y^0$  の同時分布が、割り当て変数  $z$  と独立であり、かつ、共変量の全ての値において、介入群に割り当てられる確率  $p$  が 0 より大きく 1 より小さいという条件である。これが成り立つ時にはランダムな欠測が発生している条件を満たしており、欠測しているデータを無視して、観測されているデータのみを用いて因果効果を推定できる。また、どちらの群に割り当てられるかは共変量の値のみに依存し、被説明変数による割り当てへの影響は、共変量と被説明変数の関係を通じてのみ間接的に存在しているという仮定を満たすことになり、被説明変数と説明変数の相関が明確になる。

### 強く無視できる割り当て

$$(2.7) \quad (y^0, y^1) \perp z | x, \quad 0 < p(z = 1 | x) < 1$$

共変量の影響を除去する方法には、マッチング (共変量の値が同じデータでペアを作る)、サブグループ解析 (共変量がある値のデータに限定して条件付き効果を解析する)、層別解析 (共変量の値でいくつかの層に分けて層ごとに介入群と非介入群が等質になるよう調整する)、回帰モデルを使用する (共分散分析モデル等) があるが (星野, 2009)、このうち回帰モデルを使用する方法は、割り当て変数  $z$  を共変量と共に説明変数として重回帰分析する方法である。この場合は、まず潜在的な被説明変数の共変量への回帰関数を推定し、その回帰関数を共変量について期待値をとることで、潜在的な被説明変数の周辺期待値を計算することになる。また、回帰モデルを使用する方法では、2つのグループの切片や回帰係数の推定値の差、条件付き効果は分かるが、因果効果の推定値は直接には得られない。これに対して傾向スコアを用いる方法は、複数の値をとり得る被説明変数の値と共変量との関係をモデル化する必要がなく、1次元で表現される割り当て (金融政策が実施されるかしないか) との関係モデルを設定すればよいため、モデルの誤設定の可能性が相対的に低い。また、仮にモデルの誤設定があっても、誤設定したモデル

を共分散分析で推定するよりバイアスは小さいと言われる (Drake, 1993). これに加えて, 因果効果を直接推定することができる利点もある.

傾向スコアによる調整は, 傾向スコアの推定と, 傾向スコアを用いた調整の二段階で行われる. まず, 傾向スコアを推定するために, 割り当て変数  $z$  を被説明変数, 共変量を説明変数にしたモデルを構築してパラメータを推定する. 各データ  $i$  が  $z = 1$  に割り当てられる予測確率  $e_i$  を計算して, これを傾向スコアの推定値とする. 次に, この傾向スコアの逆数を重みとした平均である IPW 推定量 (Inverse Probability Weighting Estimator) (Rubin, 1985) を計算して, これを用いて平均処置効果を計算する.

### IPW 推定量

$$(2.8) \quad \hat{E}(y^1) = \frac{\sum_{i=1}^n \frac{z_i y_i}{e_i}}{\sum_{i=1}^n \frac{z_i}{e_i}}, \quad \hat{E}(y^0) = \frac{\sum_{i=1}^n \frac{(1-z_i) y_i}{(1-e_i)}}{\sum_{i=1}^n \frac{(1-z_i)}{(1-e_i)}}$$

本研究では, 上記の IPW 推定量の分散を小さくし, かつ, 傾向スコアを算出するモデルか, 被説明変数を共変量で説明するモデルのどちらかが正しく指定されていれば, 因果効果を正しく推定することを可能にする, 二重にロバストな推定 (Bang and Robins, 2005; Hoshino, 2007) を用いた.

共変量の選定は, 理論上調整が必要な変数や, 先行研究で関連が指摘されている変数が手掛かりとなり, 扱う分野に関する知識が必要となる. 本研究では, 銀行や企業の財務変数やマクロ経済環境変数が, 企業の借入前年比に影響を与える一方, 金融政策の介入/不介入にも影響する共変量であると仮定する. また, 説明変数に用いる金融政策変数についても, 事前知識に基づいて, 引き締め, 緩和, 中立を示す離散変数を作成した. これは, その時の政策意図は一つであっても, 政策手段としては複数を用いて実施されることが多いため, 政策意図に基づいて 1 次元の変数に集約したものである. なお, 被説明変数は, 企業の借入前年比を連続変数のまま用いた.

### 2.4.3 推定に用いる変数

被説明変数として、前節で作成したデータベース $\mathbf{Y\_X}$ の企業の借入前年比を用いる。各要素は、企業 $c$ の、銀行 $b$ からの、年度 $t$ における借入前年比 $y_{c,b,t}$ である。説明変数は、金融政策変数と共変量と中間変数から成る。中間変数は、被説明変数と説明変数の間に介在し、説明変数の影響を受けて被説明変数に影響を及ぼす変数である。

共変量は、計算の効率化のためと、いたずらに推定値の分散を大きくすることを避けるために、データベース $\mathbf{Y\_X}$ から、銀行の財務変数 8、マクロ経済環境の変数を 2、企業の財務変数 35 を採用した。企業の財務変数の選択にあたっては、 $y_{c,b,t}$ をプラスであれば 1、0 以下であれば 0 の 2 値データに変換した変数 $\delta^y$ を被説明変数として、単変数ロジスティック回帰を行って、167 変数から AUC が相対的に高いグループ (AUC が 0.52 以上) に属した 35 変数を選択した。採用した共変量は、図表 4 の変数一覧のうち、○印がついている 45 変数である。

#### 企業財務変数の選択に用いた被説明変数 $\delta^y$

借入前年比 $y_{c,b,t}$ を、プラスであれば 1、0 以下であれば 0 の 2 値データに変換した変数 $\delta^y$ を作成して用いている。

$$(2.9) \quad \delta^y = \begin{cases} 0 & \text{if}(y_{c,b,t} \leq 0) \\ 1 & \text{if}(y_{c,b,t} > 0) \end{cases}$$

本節では、金融政策の介入効果を議論する都合上、金融政策変数を他の説明変数とは別に扱う。本節で使用する金融政策変数は、データベース $\mathbf{Y\_X}$ に含まれる金融政策データではなく、新たに作成する離散変数である。金融政策は複数の手段を用いて行われることもあり、景気中立的で介入がないとみなせる時と、引き締めあるいは緩和的に介入しているとみなせる時を、コールレートや日銀当座預金のデータからのみ区別することは難しい。しかし、政策実施側の意図は会見等から汲み取ることができることから、緩和的政策が採られていた時期と引き締めの政策が採られていた時期については、先行研究である程度のコンセンサスがある (Hosono and Miyakawa, 2014; Sonoda and Sudo, 2015, 2023)。そこで、緩和的な政策と引き締めの政策の 2 種類の変数を考え、それぞれ

の政策について、実施している年度は1，それ以外の期間は0を要素とする $n_t$ 行2列の金融政策変数行列 $Z^p$ を作成した（図表5）．この行列が $n_c \times n_b$ 個存在しており， $n$ 行2列の行列となっている．

図表 5 因果効果の推定で使用する金融政策変数

年度	年別データ数	$Z^p$				期間データ数
		1列目 (Tight)		2列目 (Loose)		
1982	5,463		0		1	36,086
1983	15,629		0		1	
1984	5,296	中立	0	緩和	1	
1985	2,834		0		1	
1986	6,864		0		1	
1987	12,809		1		0	
1988	12,076	引締め	1	中立	0	46,630
1989	10,911		1		0	
1990	10,834		1		0	
1991	12,238		0		1	
1992	14,009		0		1	
1993	14,970		0		1	
1994	15,304		0		1	
1995	15,196	中立	0	緩和	1	132,444
1996	15,553		0		1	
1997	14,927		0		1	
1998	16,056		0		1	
1999	14,191		0		1	
2000	12,746	引締め	1	中立	0	
2001	10,531		0		1	
2002	9,632		0		1	
2003	10,249	中立	0	緩和	1	47,244
2004	9,032		0		1	
2005	7,800		0		1	
2006	8,262	引締め	1	中立	0	
2007	8,310		1		0	
2008	7,926		0		1	
2009	7,788		0		1	
2010	7,525		0		1	
2011	7,420		0		1	
2012	6,927	中立	0	緩和	1	56,660
2013	5,760		0		1	
2014	5,188		0		1	
2015	4,163		0		1	
2016	3,963		0		1	

作成した金融政策変数を見ると，経済状態の観点からはバブル期もあれば低成長期もあり，金融政策レジームの観点からは，バブル期の大蔵省による規制や日銀による窓口規制，低成長期に入ってから伝統的金融政策に加えて非伝統的金融政策まで幅広い政策手段がとられている．各年毎のデータ数を見ると，どの年度のサンプルサイズが極端に多いということはないが，処置群と対象群の数を見ると， $Z^p$ の1列目（引き締

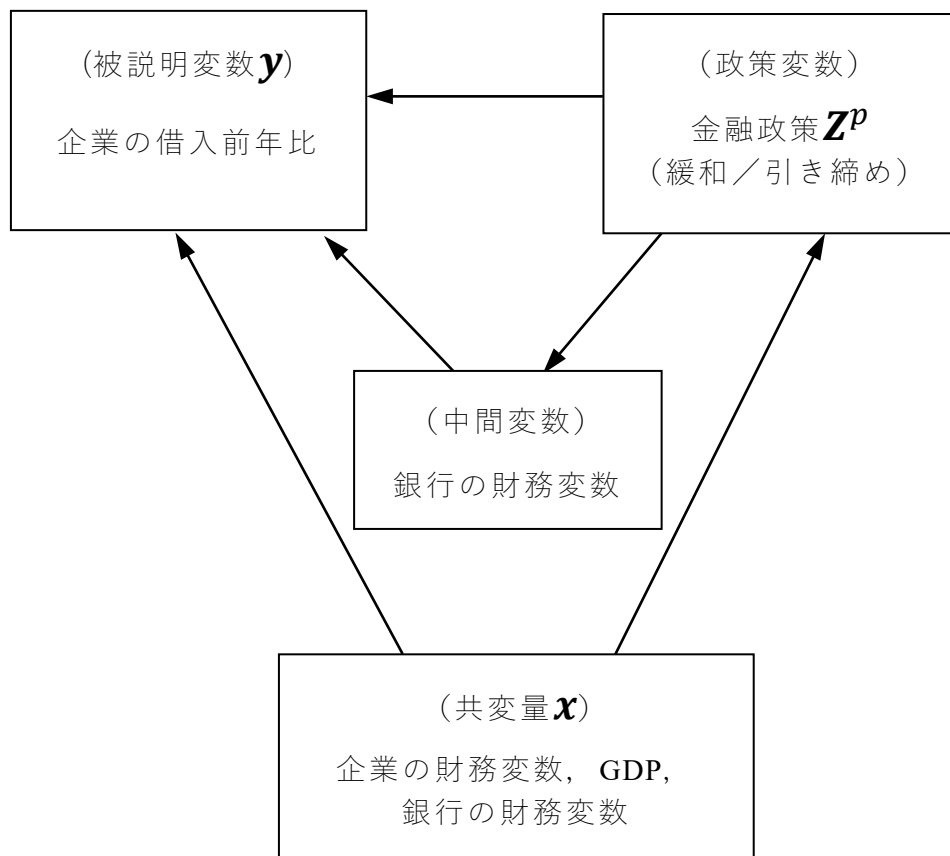
め的な金融政策の実施を示す Tight 変数) では処置群が 22% (対照群が 78%) ,  $Z^p$  の 2 列目 (緩和的な金融政策の実施を示す Loose 変数) では逆に処置群が 78% (対照群が 22%) と偏りがある。

また, 日銀が 1999 年 2 月にゼロ金利政策を導入したことを非伝統的金融政策の導入期と考えると, 1998 年度までと 1999 年度以降で分けると, 1998 年度以前の引き締めの金融政策の実施を示す Tight 変数では処置群が 22% (対照群が 78%) , 緩和的な金融政策の実施を示す Loose 変数では逆に処置群が 78% (対照群が 22%) , 1999 年度以降も, 引き締めの金融政策の実施を示す Tight 変数では処置群が 22% (対照群が 78%) , 緩和的な金融政策の実施を示す Loose 変数では逆に処置群が 78% (対照群が 22%) となっている。

#### 2.4.4 因果効果の推定で仮定する変量間の影響関係

因果関係の推定にあたって想定している変数間の影響関係は, 図表 6 のようなものである。次項で述べる推計方法を採用すると, 共変量として指定した変数についてはその影響が取り除かれて, 金融政策変数と被説明変数の相関関係をみることができる。

図表 6 因果効果の推定で想定する変量間の影響関係





金融政策は、銀行の財務変数（例えば流動資産の割合を表す財務変数）を通じて、被説明変数（企業の借入前年比）に影響すると想定する。企業の財務変数（例えば設備投資の割合を表す財務変数）は、経済の現状を表すシグナルとなって、金融政策の介入の有無に影響する一方、被説明変数（企業の借入前年比）にも影響を与えると考える。マクロ経済環境である GDP も、政策変数と被説明変数の両方に影響を与えると考える。なお、銀行の財務変数は、政策変数の影響を中継して被説明変数に影響を及ぼすだけでなく、銀行の財務変数の状況が金融政策の介入の有無に影響し、かつ被説明変数にも影響しているとも考えられる。このため、共変量については複数の設定で推計を行った。

#### 2.4.5 傾向スコアと平均処置効果の推定方法

傾向スコアの推定は、共変量  $x$  を説明変数とした金融政策変数（割り当て変数  $z$ ）の 2 値分類予測で行う。本研究は多数の共変量を持つことと、それらの多くが財務データであるために相関があること、また、金融政策変数に対して交互作用を持つ可能性があることから、モデルの誤設定をできるだけ回避しつつ、高次元のデータを使って予測精度を高める意図で、ランダムフォレストによる 2 値分類の確率推計を行った。

平均処置効果の推計は、二重にロバストな推計（Bang and Robins, 2005; Hoshino, 2007）で行う。二重にロバストな推計では、傾向スコアの推定モデルが正しく指定されているか、共変量で被説明変数を説明する回帰関数が正しく指定されていれば、因果効果の一致推定量を得ることができる（Scharfstein et al., 1999）。本研究では、傾向スコアの推定モデルについてはランダムフォレスト分類で、共変量で被説明変数を説明する回帰関数についてはランダムフォレスト回帰で行った。推計には Python の EconML パッケージが提供する Double Machine Learning (DML) と呼ばれるアルゴリズムを利用した（Chernozhukov et al., 2017, 2018）。二重にロバストな推計の具体的手続きは、①共変量で被説明変数を推計する、②共変量で政策変数を推計する、③①と②を組み合わせた最終モデルを作る、であるが、DML は③において、①の残差を②の残差に回帰して、最終モデルにおける残差をできるだけ小さくしている。また、モデル推定で用いる正則化によって拡大する傾向があるバイアスを小さくする条件（ネイマン直交条件）を加えていることと、過学習を避けるために、  
(ア) 傾向スコアと平均処置効果の推計に用いるデータを分ける、(イ)

平均処置効果の推計でデータを2分割して2度推計をして結果の平均を用いる、といったクロスフィッティングを行い、機械学習の欠点を補う工夫がされている (Chernozhukov et al., 2017, 2018) .

#### 2.4.6 モデルの推定結果と考察

平均処置効果を推計した結果が図表7である。推計は、ブートストラップサンプリングを伴う 5-fold クロスバリデーションで行った。推計に先だって、ハイパーパラメータの選択のため、ハイパーパラメータの選択に用いるデータと、モデルの構築に用いるデータと、構築したモデルの評価を行うために用いるデータとが重複しないようにした、入れ子構造の交差検証法である **Nested 5-fold Cross-validation** を、ランダムフォレスト回帰とランダムフォレスト分類の別に行った。この結果に基づいて、モデルによって用いているハイパーパラメータは異なるが、ノードの不純度の指標にジニ係数を用いた上で、ランダムフォレスト回帰については、木の深さ 3~10,木の数 3~50, ランダムフォレスト分類については、木の深さ 3~50, 木の数 3~50 を指定している。

図表 7 因果効果の推定結果(平均処置効果)

## 全データ期間

被説明変数が1982～2016年度(その他の変数は1年度前)

モデル No.	政策変数	共変量	中間変数	ATE(%)	傾向スコア 推定モデルのAUC
1	Loose	企業財務	銀行財務	-0.22	0.85
2	Tight	企業財務	銀行財務	0.26	0.85
3	Loose	企業財務とGDP	銀行財務	-0.38	0.96
4	Tight	企業財務とGDP	銀行財務	0.44	0.95
5	Loose	銀行財務	-	0.47	0.81
6	Tight	銀行財務	-	-0.54	0.84

## 非伝統的金融政策導入以前

被説明変数が1982～1999年度(その他の変数は1年度前)

モデル No.	政策変数	共変量	中間変数	ATE(%)	傾向スコア 推定モデルのAUC
7	Loose	企業財務	銀行財務	-0.20	0.99
8	Tight	企業財務	銀行財務	0.20	0.99
9	Loose	銀行財務	-	-1.72	0.99
10	Tight	銀行財務	-	-1.62	0.99

## 非伝統的金融政策導入以降

被説明変数が2000～2016年度(その他の変数は1年度前)

モデル No.	政策変数	共変量	中間変数	ATE(%)	傾向スコア 推定モデルのAUC
11	Loose	企業財務	銀行財務	-10.69	0.99
12	Tight	企業財務	銀行財務	-5.86	0.99
13	Loose	銀行財務	-	0.00	0.99
14	Tight	銀行財務	-	0.00	0.99

傾向スコアの推計に用いたランダムフォレストによる2値分類のパフォーマンスを、アウト・オブ・サンプル検証法によるAUCの計測で検証した結果、テストデータに対する予測精度のパフォーマンスはどのモデルも0.8を超えている。

全データ期間(被説明変数が1982年度から2016年度、その他の変数はその1年度前を使用)について推計した結果を見ると、企業の借入前年比に関する平均処置効果は、共変量として企業財務データを、中間変数として銀行財務データを指定したモデル1と2の結果によると、緩和

的な金融政策に対してマイナスの効果（ $-0.22\%$ ），引き締めの金融政策に対してプラスの効果（ $0.26\%$ ）と，政策の意図に反する結果になっている．また，共変量として企業財務データに加えて，マクロ経済環境である GDP 成長率を指定したモデル 3 と 4 の結果も，緩和的な金融政策に対してマイナスの効果（ $-0.38\%$ ），引き締めの金融政策に対してプラスの効果（ $0.44\%$ ）と，政策の意図に反する結果になっている．

他方，共変量として銀行財務データを指定したモデル 5 と 6 の結果によると，金融政策の緩和に対して，プラスの効果（ $0.47\%$ ），引き締めに対してマイナスの効果（ $-0.54\%$ ）と政策意図に沿った結果となっている．共変量として銀行財務データの影響を取り除いても金融政策の意図と矛盾しないが，企業財務データの影響を取り除くと矛盾することから，金融政策が銀行のバランスシートを通じて波及する効果については明らかでないが，企業のバランスシートを通じて波及する効果があることを示唆している．

次に，非伝統的金融政策が導入される以前（被説明変数が 1982 年度から 1999 年度，その他の変数はその 1 年度前を使用）と以降（被説明変数が 2000 年度から 2016 年度，その他の変数はその 1 年度前を使用）に分けて推計した結果を見る．

非伝統的金融政策が導入される以前の企業の借入前年比に関する平均処置効果は，共変量として企業財務データを，中間変数として銀行財務データを指定したモデル 7 と 8 の結果によると，緩和的な金融政策に対してマイナスの効果（ $-0.20\%$ ），引き締めの金融政策に対してプラスの効果（ $0.20\%$ ）と，政策の意図に反する結果になっている．このことは，全データ期間に対して行った推計結果と同様に，金融政策が企業のバランスシートを通じて波及する効果があることを示唆している．他方で，共変量として銀行財務データを指定したモデル 9 と 10 の結果によると，金融政策の緩和に対してマイナスの効果（ $-1.72\%$ ）となっており，金融政策の意図と矛盾する．このことから，非伝統的金融政策の導入以前は，銀行のバランスシートを通じた金融緩和政策効果があった可能性を示唆している．他方で，金融政策の引き締めに対してマイナスの効果（ $-1.62\%$ ）と，政策意図と矛盾しない結果であることから，非伝統的金融政策の導入以前においても，金融引き締め政策については，銀行のバランスシートを通じた効果は明らかではない．

非伝統的金融政策が導入された以降の企業の借入前年比に関する平均処置効果は，共変量として企業財務データを，中間変数として銀行財務データを指定したモデル 11 と 12 の結果によると，緩和的な金融政策に

対して大きなマイナスの効果（-10.69%）と、政策意図に反する結果になっている。このことは、全データ期間を用いた推計結果と同様に、緩和的金融政策は企業のバランスシートを通じて波及することを示唆していると考えられる。他方で、引き締めの金融政策に対してもマイナスの効果（-5.86%）となっており、共変量として企業財務データの影響を取り除いても政策意図と矛盾しない。これは、この期間に金融機関が企業の財務状況に関わらず、貸し剥がしと呼ばれる程の過度な信用収縮を行っていた可能性があることを示唆している。他方で、共変量として銀行財務データを指定したモデル 13 と 14 の結果によると、政策意図と反対の効果になるまでには至らないものの、金融政策の緩和に対しても引き締めに対しても効果がみられなくなる（0.00%）。緩和的金融政策について、共変量として企業財務データの影響を取り除くと反対の効果となるが、銀行財務データの影響を取り除いても中立的であることは、全データ期間を用いた推計結果と同様に、この時期においても、緩和的金融政策の波及に企業の財務データがより重要な要因であったことを示唆している。他方で、引き締めの金融政策について、共変量として企業財務データの影響を取り除いても引き締め効果があり、銀行財務データの影響を取り除くと中立的であることは、この時期においては、引き締めの金融政策の波及に銀行の財務データがより重要な要因であった可能性を示唆している。

経済理論では、金融政策は銀行のバランスシートと企業のバランスシートを通じて波及することが想定されているが、本分析の結果から示唆されることは、緩和的政策であれ引き締めの政策であれ、金融政策の波及経路としては、政策手段を実施する直接の相手である銀行のバランスシートよりも、企業のバランスシートを通じた経路の方がより重要な可能性があるということである。但し、非伝統的金融政策を導入した 2000 年度以降については、企業のバランスシートに関係なく引き締め効果が見られるという例外があった。他方で、銀行のバランスシートを通じた効果が示唆されたのは、1999 年度以前の緩和的な金融政策についてのみである。政策立案の立場からは、この経験から、2000 年度以降も銀行のバランスシートを通じた金融緩和を期待したのかもしれないが、結果としてその効果は示唆されていない。

この他にわかったことは以下の通りである。全データ期間を用いた推計結果によると、企業財務や銀行財務を共変量として調整した場合に、金融政策が企業の借入前年比に及ぼす効果は、緩和であれ引き締めであれ、絶対値で 1%にも満たない。銀行のバランスシートと企業のバランス

シートの両方が金融政策の波及経路である可能性があるのに、共変量として何れかの影響を除去している分、効果を過小評価している可能性があるものの、平均処置効果で見た場合の影響は大きくないと評価できる。

また、共変量とした企業の財務変数 35 変数について、ジニ不純度を基準とした重要度を考察すると、ランダムフォレスト回帰とランダムフォレスト分類、全データ期間及び非伝統的金融政策の導入前後に分けた分析を通じて、重要度上位 10 位までに上がる回数が多かった変数は、減価償却率、有形固定資産原価償却累計率、資本市場調達・借入比率、増収率、純運転資本額、有利子負債額、現金・預金対有利子負債比率であった。

## 2.5 まとめと今後の課題

本研究では、金融政策の波及経路を検証するために統計的因果推論の枠組みで金融政策の介入による平均処置効果を推定した。この結果、データ全期間（1982 年度から 2016 年度）を通じてみると、企業の借入前年比に対して、銀行のバランスシートを通じた金融政策の波及は明らかでないものの、企業のバランスシートを通じた波及が示唆された。これは、銀行の資金供給よりも企業の資金需要の要因が強いことを示唆しているとも考えられる。また、データ期間に限らず、また引き締めか緩和かに関わらず、平均で見ると金融政策の影響度合いは大きくないこともわかった。

今後の課題は以下の通りである。日本における非伝統的金融政策は、1999 年 2 月のゼロ金利政策導入以降、同年 4 月の時間軸政策（フォワードガイダンス）導入（デフレ懸念の払しょくが展望できるような情勢になるまで現在の政策を続けると約束）、2001 年 3 月の量的緩和の導入（金融市場調節の目標を無担保コールレートから日銀当座預金残高に変更）、2008 年 11 月の大規模な資産買入れの導入（リスク性資産である住宅ローン担保証券に加え国債を大規模に買入）、2012 年 7 月のマイナス金利政策の導入、2016 年 9 月のイールドカーブ・コントロールの導入（短期金利を -0.1%、長期金利を 0% 程度で維持）とオーバーシュート型コミットメント（消費者物価上昇率の実績値が安定的に 2% を超えるまでマネタリーベースの拡大方針を継続すると約束）が行われている。またこの間、新たな政策の導入ではないが、2013 年 4 月以降は量的・質的金融緩和と称して、先行きの金融政策運営方針に関するコミットメントを行ったほか、大規模な国債買入れによる長期金利の押し下げ、ETF 等リスク

性資産買入による株式市場等のリスク・プレミアムへの働きかけを行うなどもしている。本研究では金融政策を離散変数に変換したが、引き締めと緩和の2区分では、これら様々な政策手段の違いを表現することはできない。他方で、一連の政策は、それまでの政策では効果が不十分として重ねて行われている側面があることから、別の変数として取り扱うよりは、離散データであっても政策の性質の違いを表現できるような手段のまとめ方や、緩和の強さを表現する工夫、また、複数の政策手段における政策変更のタイミングの情報を集約するような工夫を考える余地がある。

なお、非伝統的金融政策の導入以降に限れば、短い期間を除いて緩和政策が採られ続けていることから、分析対象期間を、今回対象とした2016年度以降に延長するほど、非介入データが相対的に少ないデータで平均処置効果を推計することになる。このことは分析の枠組みの限界として、今後、非介入期のデータの集積を待って分析する事が望ましいと考えられる。2023年4月に日銀が「1990年代後半以降、約25年続けてきたさまざまな金融緩和策のレビューを、1年から1年半程度かけて行う」と声明を出したように、伝統的金融政策において、短期金利の操作がほぼタイムラグなしに経済主体に波及したのとは異なり、非伝統的金融政策は、金融政策の表明、実施、効果が出るまでにそれぞれタイムラグがあると想定されることから、長期的な視野での検証が必要である。

この他、共変量の選定について再検討する余地がある。例えば、2013年4月の量的・質的金融緩和によって、為替市場で円安傾向が促進され、これを通じて株価が上昇したことは、金融政策が金融市場の期待に一定の影響を及ぼしたことを示しており、このことが企業や銀行のリスクテイクに影響を与えた可能性がある。このため、為替のような国際金融市場に関するデータの取り入れを検討すべきと考えられる。また近年、コロナ感染症の世界的拡大に伴って世界経済全体が縮小し、回復の軌道に乗ったかという時期にウクライナにおける戦争が起こったことから、国際金融・商品市場が大きな影響を受けた。これら世界的な事象に対して各国の中央銀行が採る金融政策は、国際金融市場を通じて、その国にとどまらない影響を及ぼしている。このことから、国際金融市場に大きな影響を及ぼす米国のFRBや欧州のECBの政策金利なども共変量に含めることを検討すべきと考えられる。また、平均処置効果の推定に用いたDMLは、現状では計算コストがかかるために取り入れることができる変数の数に限りがある。本研究では銀行の財務変数8、企業の財務変数35を用いたが、より幅広い変数を検討することが望ましい。また、これを

実現した上で金融政策変数と企業の借入前年比の双方を離散変数として分析すると、より現実に即したものになる可能性がある。

より根本的には、分析対象データを拡大することが望ましい。本分析で用いたデータのカバレッジは上場企業と都市銀行及び地方銀行、種類は財務データに限られるが、より多種のデータベースをリンケージすれば、別の側面から見た銀行や企業の属性別の結果を得ることや、より普遍的な結果を得ることが可能になると考えられる。



## 第3章

# ランダムフォレストの感度分析による金融政策効果と波及メカニズムの検証

### 3.1 導入

第2章で行ったルービンの因果効果による金融政策の波及効果の分析は、モデルの誤設定によって推定にバイアスが生じる可能性を二重にロバストな推計を用いることで回避しているが、それでも共変量の選定に伴う難しさは残る。そこで、本章では、多くの変数に対してランダムフォレストのアルゴリズムを用いて、データ適合的な決定木を体系的に探索した後に、その決定木を解釈するべく、金融政策のショックに対する被説明変数の反応を見る感度分析を行う。金融政策は銀行や企業のバランスシートを通じて拡大を伴って波及すると想定されているが（Bernanke and Gertler, 1995）、機械学習の手法で構築した決定木は、事前に関数形を指定する必要も、ダミー変数を導入する必要もなく、交互作用も表現できる。但し、オーバーフィッティングをコントロールする必要がある。また、関係式が明示的に得られないため、変数間の関係を知るには、感度分析など別に用意が必要である。

#### 3.1.1 分析の概要

企業と銀行が、取引関係を維持することにメリットがあると考えなどの理由で、企業が毎期金利のみを返済したために企業の借入前年比が変化しないケースが多い中で、金融政策は、企業や銀行が「どれだけ」借入（貸出）を増やすかという連続的な意思決定よりは、借入（貸出）を「増やすか否か」という、離散的な意思決定に影響を与えていると考え

することもできる。このため、企業の借入前年比が増加したか否かを示す離散変量に変換して被説明変数に用いた。他方で、金融政策変数は連続変数のまま、銀行や企業の財務変数やマクロ経済環境変数と共に説明変数に用いた。金融政策変数については、伝統的な金融政策を表す変数としてコールレートを、非伝統的な金融政策を表す変数として日銀当座預金を用いた。近年、金融政策手段は多様化しており、短期金利操作と異なって、タイミングが即時であるとは限らず、また、複数の手段で異なるタイミングになることもあり得るが、最終的には日銀当座預金の増減に反映されるためである。

分析手法としては、ランダムフォレスト (Breiman, 2001a) による予測モデルを構築し、機械学習モデルを解釈する手法として、説明変数が被説明変数にどのように影響しているかを可視化した部分依存プロット (Partial Dependence Plot, PDP) (Friedman, 2001), Accumulated Local Effect (ALE) (Apley and Zhu, 2020), 及び交互作用を可視化した2次元 ALE による金融政策への感度分析を行った。

### 被説明変数 $\delta^y$ : 離散変数

借入前年比を離散的行動データとして扱う  $y_{c,b,t}$  を、プラスであれば 1, 0 以下であれば 0 の 2 値データに変換した変数  $\delta^y$  を作成して用いている (2.10 式と共通)。

$$(3.1) \quad \delta^y = \begin{cases} 0 & \text{if}(y_{c,b,t} \leq 0) \\ 1 & \text{if}(y_{c,b,t} > 0) \end{cases}$$

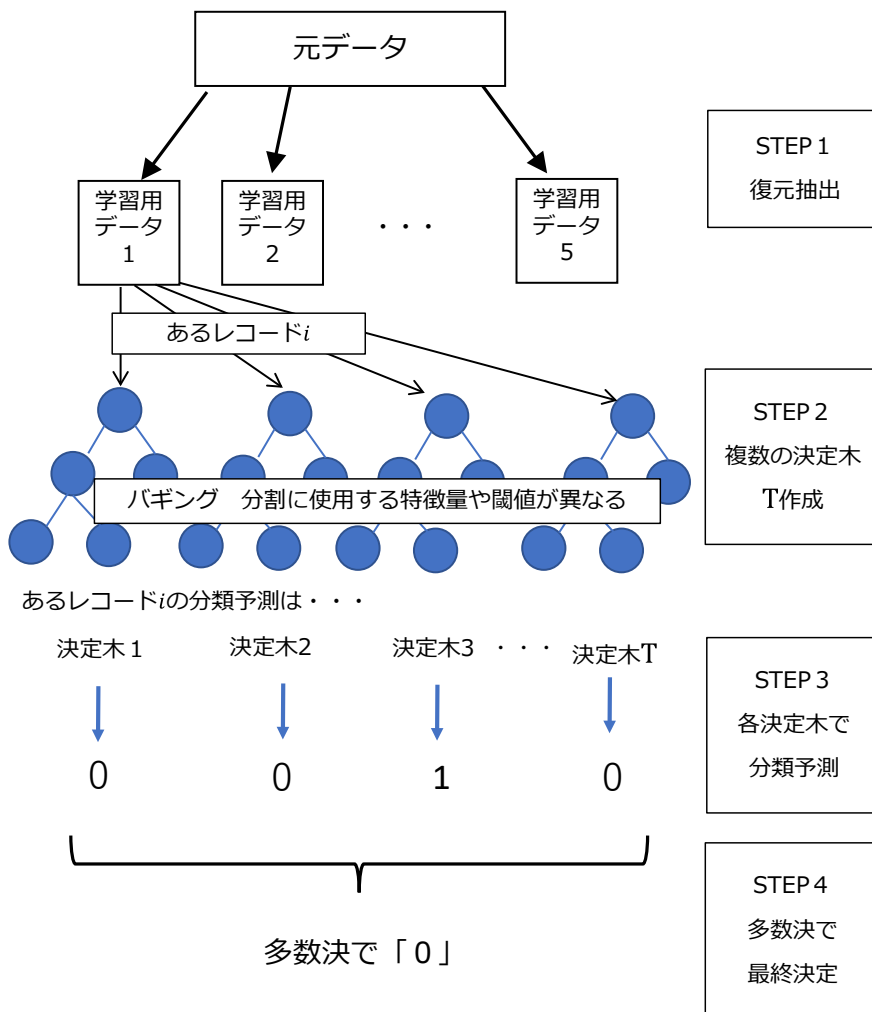
## 3.2 ランダムフォレストと勾配ブースティングによる分類推定

機械学習の手法のうちランダムフォレストと勾配ブースティング決定木アルゴリズムに基づいて、企業の借入前年比  $y_{c,b,t}$  がプラスになるか否かを分類予測する決定木を構築する。図表 8 は、ランダムフォレストアルゴリズムと勾配ブースティングアルゴリズムの概要図である。勾配ブースティング決定木は、アンサンブル学習において、ランダムフォレストのように複数の決定木を並列的に作成するバギングではなく、ある一つ

をベースとして学習させて、誤判定を正しく判定できるよう直列的に決定木を更新してゆく。


図表 8 決定木ベースのアルゴリズム

### ランダムフォレスト



## 勾配ブースティング(図表8続き)

誤分類を減らすように直列更新



決定木では、0がほとんどを占める特徴量は、ツリーが分割するごとに2つの値(0か1)しか選べないため、変数としての重要度が相対的に高くなるとは考えづらい。このため、先行研究で用いられてきたパネル回帰分析とは異なり、ダミー変数は導入しない。また、ランダムフォレストと勾配ブースティングとも、交互作用項に意味があれば木の構造の中で表現されることが期待できるため、交互作用項も取り込まない。

$i$ 番目の被説明変数を $\delta_i^y$ 、その説明変数を $x_i$ とすると、目的変数 $f(x)$ は $x_i$ の下で $\delta^y$ が1である確率を表す。

$$(3.2) \quad f(x) = P_r(\delta_i^y = 1 \mid x_i)$$

また、 $f(x)$ は、説明変数 $x_i$ に対する未知の関数 $g$ の作用の結果の全てにおいて、 $E[\{\delta_i^y - g(x_i)\}^2]$ を最小にするものとする。

$$(3.3) \quad \hat{f}(x) = \arg \min_g E \left[ \{\delta_i^y - g(x_i)\}^2 \right]$$

推計の目的は、縮小可能な誤差 $[f(x) - \hat{f}(x)]^2$ が最小となるような、説明変数 $x$ のパラメータ $\beta$ を見つけて、 $f(x)$ が推定値である $\hat{f}(x)$ と一致するようにすることである。本研究では、 $\beta$ を推計するためにランダムフォレストを使った。その際、アルゴリズムとして Python の `scikit-learn` ライブラリを、勾配ブースティングのアルゴリズムとして Python の `LightGBM` を使用した。

アルゴリズムに適用する最適なパラメータ（ハイパーパラメータ）の選択は、ハイパーパラメータの選択に用いるデータと、モデルの構築に用いるデータと、構築したモデルの評価を行うために用いるデータとが重複しないように（重複がもたらす最適モデルの選択バイアスについては [Cawley and Talbot, 2010](#) を参照）入れ子構造の交差検証法である `Nested 5-fold Cross-validation` で行った。まず、ランダムフォレストと勾配ブースティングそれぞれに、ハイパーパラメータとしていくつかの候補を与えて、`5-fold` クロスバリデーションにおける AUC 評価で精度が最も高い値をそれぞれ選択する。次に、それぞれ最も適したパラメータを適用したランダムフォレストと勾配ブースティングモデルを比較するために `5-fold` クロスバリデーションにおける AUC 評価を行い、最後に、テストデータを用いて未知のデータに対する予測精度を評価している。図表 9 はランダムフォレスト、勾配ブースティングの各モデルについて検討したハイパーパラメータの値、及び最終的に使用したハイパーパラメータである。なお、データはブートストラップでサンプルサイズと同数が重複ありでランダムにサンプリングされている。

図表 9 決定木モデルのハイパーパラメータの候補と選択(下線)

RF

critierion	ノードの不純度の指標	<u>gini,entropy</u>
max_depth	木の深さ	1,5,10,14, <u>20</u> ,30
n_estimators	木の数	1,10, <u>100</u>

GB

num_leaves	葉の数	30,100, <u>1000</u>
learning_rate	学習率	0.01, <u>0.1</u>
min_child_samples	末端ノードに含まれる最小のデータ数	<u>100</u> ,1000
colsample_bytree	木を作成する際に使用する特徴量の数を選択する割合	0.8
subsample	使用するデータの選択割合	0.8
reg_lambda	L2 正則化	0.01, <u>0.1</u>

## モデルの精度比較に用いた各種指標の定義

		実 際	
		借入前年比プラス	借入前年比 0 未満
モデル による 分類	借入前年比プラス	TP(真陽性)	FP(偽陽性)
	借入前年比 0 未満	FN(偽陰性)	TN(真陰性)

**TP(True Positive) :**

実際は借入前年比プラス、かつ、正しくプラスと予測された数

**TN(True Negative) :**

実際は借入前年比 0 未満、かつ、正しく 0 未満と予測された数

**FP(False Positive) :**

実際は借入前年比 0 未満だが、誤ってプラスと予測された数

**FN(False Negative) :**

実際は借入前年比プラスだが、誤って 0 未満と予測された数

**AUC (Area Under the Curve) :**

ROC 曲線 (Receiver Operatorating Characteristic curve) の下側部分の面積で定義される指標。AUC はモデルの順位性 (借入前年比がプラスになる確率の高い (低い) 企業ほど借入前年比がプラス (0 以下) になっているか) を評価するための指標であり、この値が大きいほど予測精度が高いといえる。

正解率 (Accuracy, 全予測正答率) :

$$\frac{TP + TN}{TP + FP + FN + TN}$$

陽性的中率 (**Precision**, プラス予測の正答率) :

$$\frac{TP}{TP + FP}$$

陰性的中率 :

$$\frac{TN}{FN + TN}$$

### 3.2.1 推定に用いる変数

被説明変数には、 $\delta^y$ を、説明変数には、第2章で構築したデータベース  $\mathbf{Y\_X}$  (図表3) から  $\mathbf{y}$  を除く説明変数行列  $\mathbf{X}$  を用いる。すなわち、第2章と異なり、金融政策変数に  $\mathbf{x}_z$  を用い、伝統的な金融政策を表す変数としてコールレートを、非伝統的な金融政策を表す変数として日銀当座預金を用いる。

金融政策の効果を検証する観点からは、正確率と陽性的中率が高いことが望ましい。他方、企業の財務環境が銀行の融資審査を通るような数字であっても、また、マクロ経済や金融政策環境が銀行の貸出や企業の借入を後押しするような環境であったとしても、企業に資金需要がなければ融資の申込みはなく、借入前年比プラスの状況も発生しない。逆に、前期の企業の財務環境が悪くなくとも、何らかの理由でメインバンクが救済にあたることは考えられる。このため、FP (偽陽性) や FN (偽陰性) の値はこのような実態の影響を受ける可能性がある。なお、分析対象としていたデータは借入前年比プラス (クラス1) よりも0未満 (クラス0) の方が多いため (クラス0はクラス1の約2倍存在する)、陰性的中率は高いと想定される。

### 3.2.2 感度分析の方法

Partial Dependence Plot (以下、PDプロット) は、注目する説明変数ベ

クトル（本研究では金融政策変数 $\mathbf{x}_z$ やマクロ経済変数 $\mathbf{x}_q$ 、以下では $\mathbf{x}_z$ を例とする）が他の変数と相関していない事を仮定して、 $\mathbf{x}_z$ の値のみが変化した時、被説明変数ベクトル $\mathbf{y}$ が平均してどのように変化するかをグラフで示したものである。但し、相関がないという仮定が成り立たない時には、ある値を $\mathbf{x}_z$ に強制した結果、実際にはありえないようなデータポイントが含まれて結果が偏る可能性がある。本研究が注目する金融政策変数は、その他の変数にとっては外生ショックであると考えられ、この仮定を満たしているようにも思えるが、他方で、経済理論は、 $\mathbf{x}_z$ は他の変数（例えば銀行の財務変数ベクトル $\mathbf{x}_s$ ）と独立ではなく、かつ、交互作用を持つと考えている。そこで、 $\mathbf{x}_z$ と $\mathbf{x}_s$ の条件付分布 $p(\mathbf{x}_z|\mathbf{x}_s)$ を考え、かつ、予測の変化の平均を計算することで、 $\mathbf{x}_z$ および $\mathbf{x}_s$ 単独の効果と、 $\mathbf{x}_z$ と $\mathbf{x}_s$ の交互作用をそれぞれ別に表す2次元の Accumulated Local Effects（以下、ALE）プロットによる感度分析も行った（Apley and Zhu, 2020）。経済理論が提示している金融政策変数と銀行の財務データ変数の相互作用効果が存在しなければ、2次元 ALE プロットの値は0に近い値になる。感度分析のアルゴリズムには R の ALEPlot を使用した。

### 3.3 モデルの推定結果

図表 10 は、ランダムフォレストと勾配ブースティングそれぞれで、モデルの構築に用いなかった未知のデータの分類予測を行い、その結果を比較した結果である。Nested 5-fold Cross-validation を 3 回行った結果、最も大きい AUC 値であった回の結果を表している。正解率はランダムフォレストが 0.76、勾配ブースティングは 0.77、陽性的中率はランダムフォレストが 0.71、勾配ブースティングが 0.68 と高いと言える値であった。偽陽性率は、ランダムフォレストが 0.06、勾配ブースティングが 0.09 と想定外に小さかったが、そもそも企業に資金需要がなければ借入前年比プラスの事象が発生しえないという、予測に不利な前提条件よりも、被説明変数に前年比 0 未満のデータが多く当てやすかったことが影響していると考えられる。他方、想定通り、偽陰性率の値はランダムフォレストが 0.66、勾配ブースティングが 0.55 と高い。これは、モデルの枠外で、メ



インバンク等の救済が行われてきた証左ではないかと解釈できる。

AUCに基づいて精度比較すると、ランダムフォレスト（0.798）に対して勾配ブースティングモデルは（0.802）だった。

図表 10 決定木モデルの評価

各種評価指標					
	TP	TN	FP	FN	
RF	9,011	57,216	3,685	17,184	
GB	11,883	55,224	5,677	14,312	

	正解率	陽性的中率	陰性的中率	真陽性率	真陰性率
RF	0.76	0.71	0.77	0.34	0.94
GB	0.77	0.68	0.79	0.45	0.91

	偽陽性率	偽陰性率
RF	0.06	0.66
GB	0.09	0.55

AUC			
	5-fold 平均	5-fold 標準偏差	標準正規分布を仮定した90%信頼区間
RF	0.798	0.0016	[ 0.796 , 0.801 ]
GB	0.802	0.0018	[ 0.799 , 0.805 ]

### 3.3.1 感度分析の結果

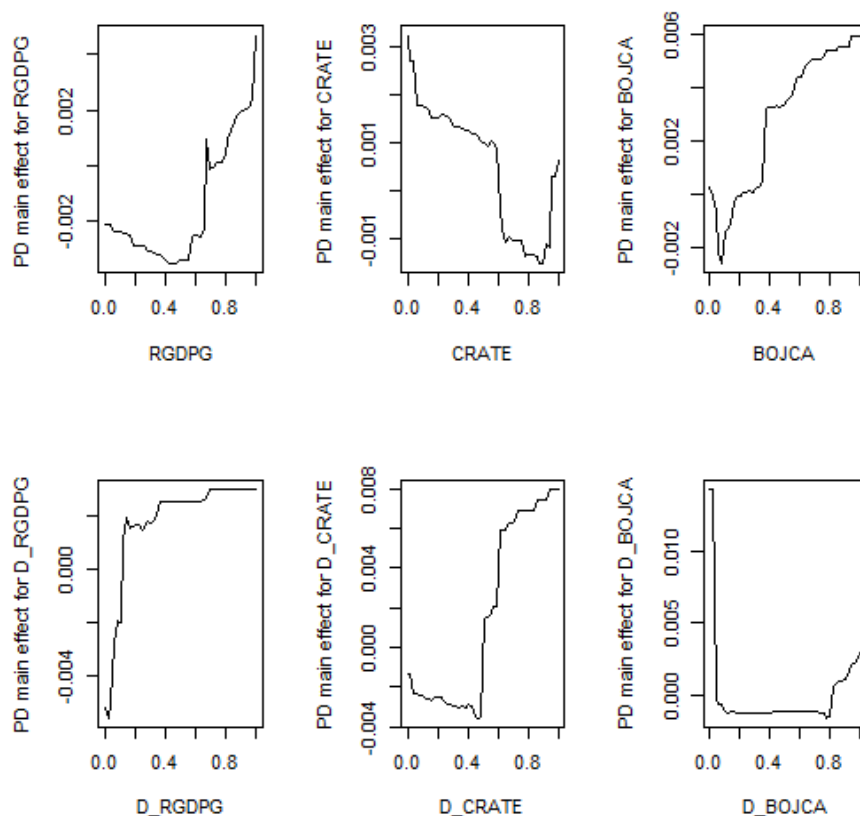
#### マクロ経済変数と金融政策変数に対する Partial Dependence Plot の結果

図表 11 は、構築したランダムフォレストに基づいて、全てのデータを利用して計算した PD プロットである。マクロ経済変数（実質 GDP 成長率，実質 GDP 成長率前年度差）と金融政策変数（コールレート，コールレート前年度差，日銀当座預金残高，日銀当座預金残高前年度差）に対する，企業の借入前年比がプラスになる確率の反応を示している。コールレートと日銀当座預金は自然対数に，それ以外は `neglog` 変換した後，0～1 の範囲に変換しているため，0 は各変数の過去の観測値の最小値，1 は最大値を示す。また，0.1 刻みのラベルは 10 分位ではなく，相対的に小さい観測値を強調した表現になっている。

#### 横軸（カッコ内は観測最小値～最大値，単位）

- ・ `RGDPG`：実質GDP（-3.6～6.2，%）
- ・ `CRATE`：コールレート（0.00～7.77，%）
- ・ `BOJCA`：日銀当座預金（23,928～3,086,667，億円）
- ・ `D_RGDPG`：実質GDP前年度差（-4.7～5.7，%）
- ・ `D_CRATE`：コールレート前年度差（-2.77～2.02，%）
- ・ `D_BOJCA`：日銀当座預金前年度差（-212,845～760,021，億円）

図表 11 マクロ経済変数と金融政策変数に対する Partial Dependence Plot



6つのグラフを見渡すと、何れの変数も企業の借入前年比がプラスになる確率に与える影響は極めて小さい。縦軸の最大値を拾って見ると、概ね、実質 GDP 成長率で最大 0.4%（前年度差は 0.3%）、コールレートで最大 0.3%（同 0.8%）、日銀当座預金で最大 0.6%（同 1.5%）である。

グラフの形状を見ると、単調に増加、あるいは単調に減少しているものはない。実質 GDP のグラフを見ると、過去の実質 GDP（-3.6~6.2）を 0~1 の範囲に変換すると、概ね 0.5 までは借入が増加する確率を減少させる効果があり、それ以上になると一転して増加させる効果を持つ。金融政策変数であるコールレートのグラフを見ると、過去のコールレート（0.00~7.77）を 0~1 の範囲に変換すると、0.6~0.9 の範囲で金融引き締め効果が見られるものの、この範囲以外はむしろ逆である。過去の日銀当座預金（約 2~310 兆円）を 0~1 に変換すると、概ね 0.4 あたりで急に効果が大きくなるが、それより大きい値での効果の増加は緩やかで

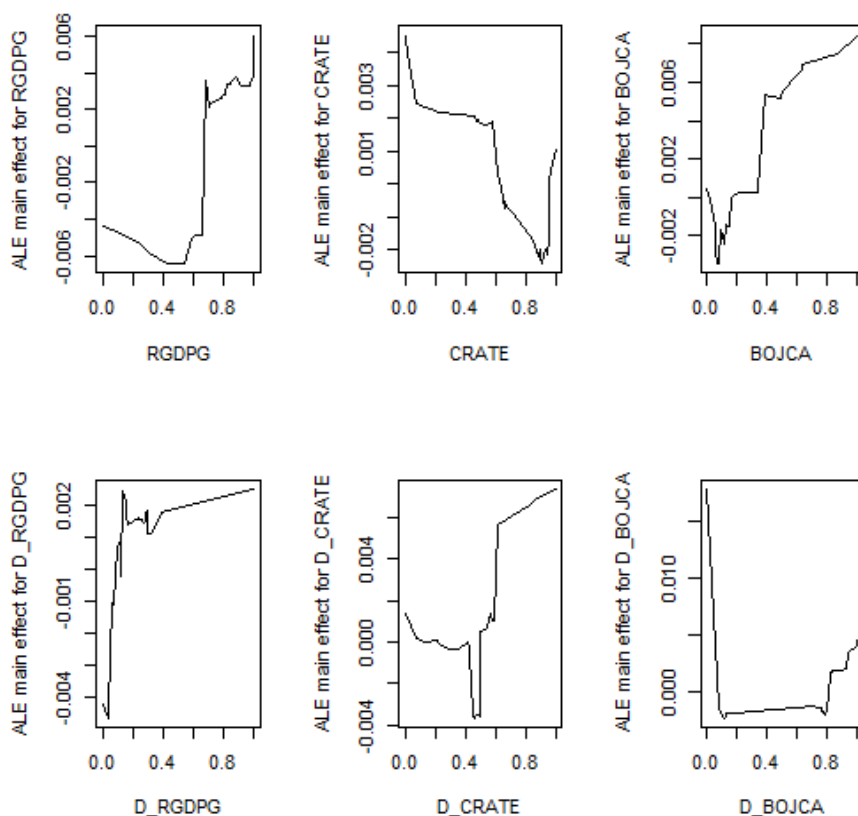
ある。

また、実質 GDP 前年度差のグラフを見ると、過去の実質 GDP 前年度差（ $-4.7 \sim 5.7$ ）を  $0 \sim 1$  の範囲に変換すると、概ね  $0.1$  以上では横ばいになっている。同様に、過去のコールレート前年度差（ $-2.77 \sim 2.02$ ）を  $0 \sim 1$  の範囲に変換すると、概ね  $0.5$  を閾値に反応が逆転しているほか、閾値を挟んで横ばいに近い動きになっている。過去の日銀当座預金前年度差（約  $-21 \sim 76$  兆円）を  $0 \sim 1$  の範囲に変換すると、 $0.1$  以下と、 $0.8$  を超えたあたりで増加効果が示唆されている。

### マクロ経済変数と金融政策変数に対する Accumulated Local Effect の結果

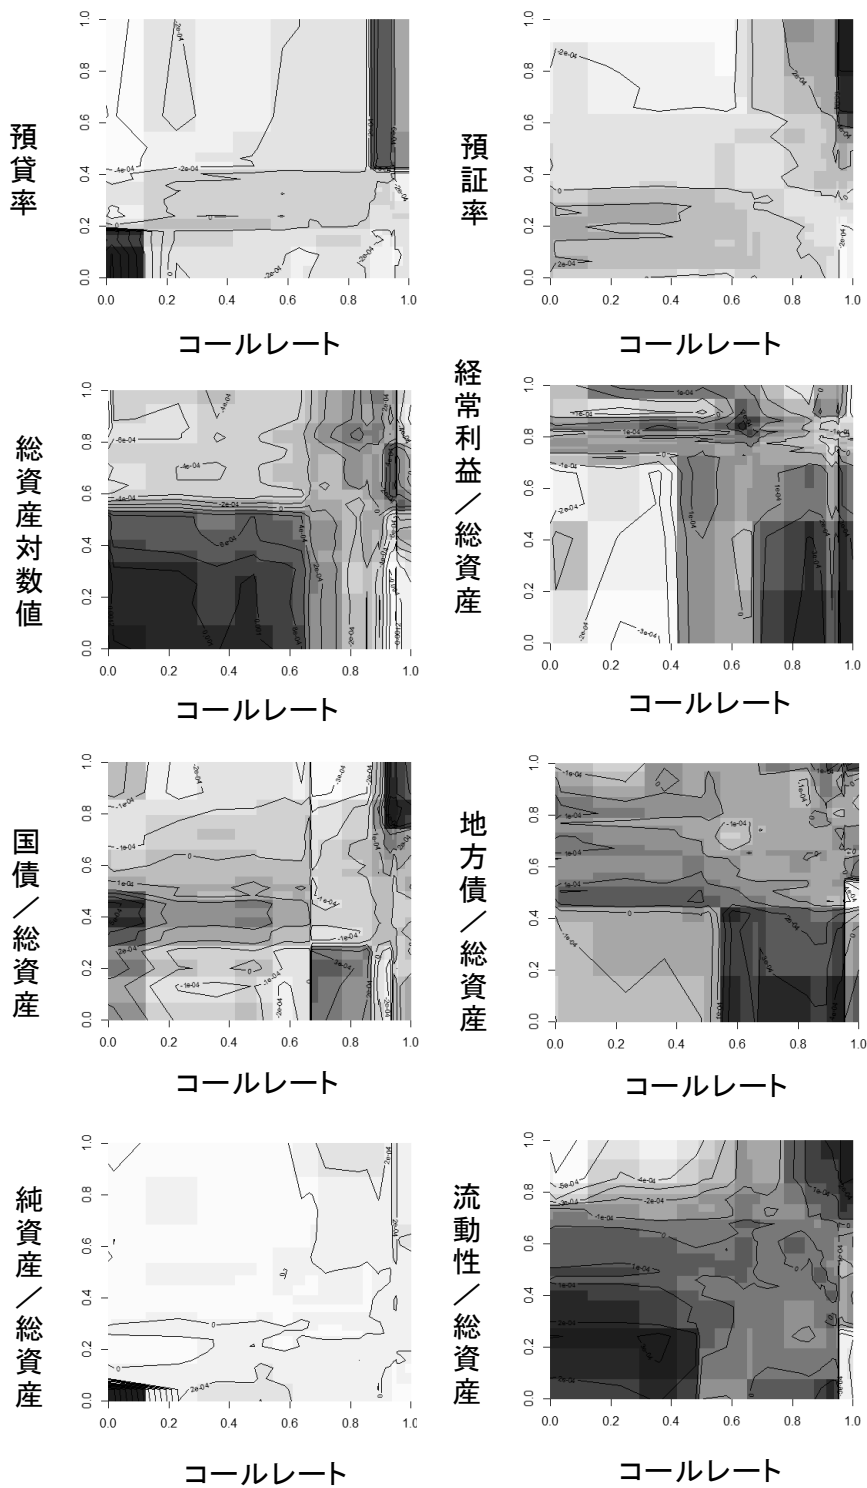
図表 12 は、ALE による単独効果のプロットである。PD プロットで見られた急激な変動が、PD プロットの仮定に起因する、実際にはありえないようなデータの影響である場合、ALE プロットではそれが取り除かれている。両者を比較すると、PD プロットで見られた急激な変動は ALE プロットでも確認されており、こうした錯誤はないことが確認できる。

図表 12 マクロ経済変数と金融政策変数に対する Accumulated Local Effect (ALE): Main Effect



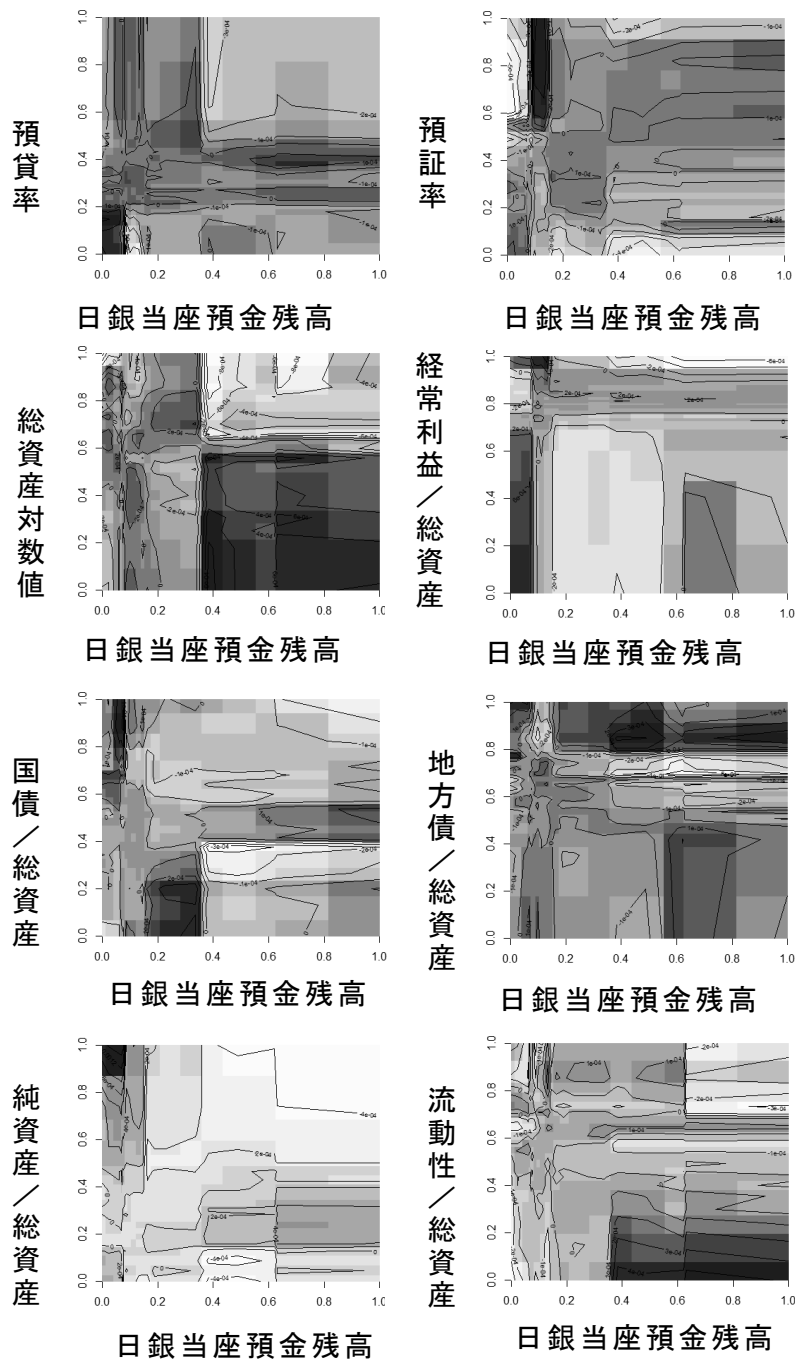
図表 13 は 2 次元 ALE による交互作用のプロットである.金融政策変数 (コールレート, 日銀当座預金) と 8 つの銀行の財務変数 (預貸率, 預証率, 総資産, 経常利益, 国債, 地方債, 純資産, 流動性, なお, 経常利益, 国債, 地方債, 純資産, 流動性は総資産で割ってある) の組み合わせについて, 単独効果に追加するような交互作用があれば, ヒートマップの色が濃く表示されている.ヒートマップ毎に最も濃い色が示す値は異なる.

図表 13 金融政策変数に対する Accumulated Local Effect (ALE): Second-order



## 金融政策変数に対する Accumulated Local Effect (ALE): Second-order

(続き)



コールレートと8つの銀行の財務変数の組み合わせのグラフを見ると、過去のコールレートの値を0～1の範囲に変換した時、概ね0.8以上と相対的に高い部分については、銀行の預貸率が同0.4以上の部分と、銀行の預証率が同0.6以上の部分、銀行の国債保有割合が同0.8以上の部分との組み合わせで、ヒートマップが濃い色を示している。逆にコールレートが概ね0.1以下と相対的に低い部分については、銀行の預貸率が同0.2以下の部分、総資産の対数値が同0.4以下の部分、銀行の保有流動性が同0.4以下の部分との組み合わせでヒートマップが濃い色を示している。

日銀当座預金と8つの銀行の財務変数の組み合わせのグラフを見ると、日銀当座預金残高の水準が概ね0.6以上と相対的に高い部分については、銀行の規模（総資産の対数値）を0～1の範囲に変換した時に0.2以下の部分や、銀行の保有流動性が同0.2以下の部分との組み合わせでヒートマップが濃い色を示している。

### 3.3.2 感度分析の結果から見た金融政策効果と波及メカニズムの考察

PDプロットの結果からは、銀行を通じた企業向け金融は実質GDP成長率がマイナスの間は不活発だが、閾値を超えると一気に活発化することが窺える。また、金融政策変数であるコールレートについても、一定の範囲では金融引き締め効果が見られるものの、この範囲以外はむしろ逆である。特に、大きな値（過去のコールレートを0～1の範囲に変換した時、0.9を超えると）で企業の借入れ前年比がプラスになる確率が高まっているように見えるのは、1980年代後半を中心としたバブル期に、過度な金融を抑制しようとしたものの、金利の引き上げでは足りず、日銀による窓口規制や当時の大蔵省による総量規制も加わった事と矛盾しない。日銀当座預金の金融緩和効果はある閾値で見られるものの、それより大きい範囲ではほぼ横ばいである。このように、コールレートと日銀当座預金の2つの金融政策変数の効果があるのは限られた範囲のみと考えられる。実質GDP前年度差については、実質GDPが大幅に下落した2008年の国際的金融危機とその直後あたりを除くと、借入前年比が増加する確率との間にあまり関係がないことを示唆している。コールレート前年度差については、変化幅自体には意味がないことを示唆している。なお、コールレートの変化がマイナスの時に企業の借入前年比がプラスになる確率が減少し、プラスの時に増加するのは、金融政策の意図とは逆であ



り、企業の借入前年比がプラスになる確率の決定要因として資金供給よりは資金需要の方が大きいことを示唆している。日銀当座預金前年度差について、減少している部分で企業の借入前年比が増加する確率が高まっていることは、資金需要の強さを示しているものと考えられる。

2次元 ALE プロットの結果からは、コールレートが相対的に高く、銀行の預貸率が高い部分でヒートマップの色が濃くなっている点について、バブル期に金融政策が引き締めにかかったものの効果がなかったことと矛盾しない。銀行の預証率や銀行の国債保有割合が高い部分でもヒートマップの色が濃くなっているのは、有価証券での運用が過熱的な状況だったことを示唆している。他方、金融緩和の効果や、金融緩和が銀行のリスク選好に影響を及ぼすという、リスクテイキング・チャンネルに関連して興味深いのは、コールレートが相対的に低い時にヒートマップが濃い色を示している部分である。銀行の預貸率が低い部分との組み合わせでヒートマップの色が濃いことは、相対的に企業向け金融での預金の運用が少ない銀行も、コールレートが低い金融緩和的な状況下では、追加的に企業向け金融を活発化させていることを示唆している。総資産の対数値が相対的に小さい部分との組み合わせでヒートマップの色が濃いことは、規模が小さい銀行が、金融緩和的な状況下で、企業向け金融を活発化させていることを示唆している。銀行の保有流動性が相対的に低い部分との組み合わせについても同じ事が言える。これらは、金融緩和政策が銀行のリスク選好に影響を及ぼすという、リスクテイキング・チャンネルの存在を示唆する結果となっている。

日銀当座預金残高の水準が相対的に高い状況の時にヒートマップが濃い色を示している部分についても、同様の示唆が得られる。銀行の規模（総資産の対数値）が相対的に低い部分との組み合わせや、銀行の保有流動性が相対的に低い部分との組み合わせでのヒートマップの色の濃さは、規模が小さい銀行や、保有流動性が低い銀行にとって、緩和的な金融政策環境が、企業向け貸出を活発化させる誘因になっていると解釈できる。

### 3.4 まとめと今後の課題

本研究では、金融政策の効果を検証するために、ランダムフォレストを用いてデータ適合的なモデルを体系的に探索し、感度分析によって選定されたモデルの解釈を行った。この結果、企業の借入前年比が増加す

るか否かへの影響は、銀行の資金供給よりも企業の資金需要の要因が強いこと、金融政策は、引き締めや緩和の水準や変化の幅よりは、政策を転換したことが影響を与えている可能性が高いこと、また、緩和的な金融政策が、銀行のリスク選好に影響を与えている可能性が示唆された。

今後の課題は以下の通りである。本研究の結果、金融政策は水準や変化幅より政策転換に意味があることが示唆されたことから、金融政策変数として、コールレートや日銀当座預金そのものを用いるのではなく、政策変更のタイミングがわかるように情報を集約した離散変数を用いるなど工夫する余地がある。また、本研究ではランダムフォレスト使用する変数には国内経済に関する変数を使用し、海外経済の情報は間接的にしか含まなかったが、近年、コロナ感染症の世界的拡大やウクライナにおける戦争が起こるなど、国際的な財やサービスの取引、国際商品市場や国際金融市場が世界同時的にショックを受けている。これに対して各国の中央銀行が採る政策も、国際金融市場を通じてその国にとどまらない影響を及ぼしている。このほか、アベノミクスと呼ばれる量的緩和のブースティングによる株価上昇は、企業や銀行のリスクテイクに影響を及ぼした可能性がある。このことを踏まえると、国際商品市場、金融市場を代表する変数についても含めると、より予測精度が向上する可能性がある。

第2章で行った研究の課題と同様に、より根本的には、分析対象データを拡大することが望ましい。本分析で用いたデータのカバレッジは上場企業と都市銀行及び地方銀行、種類は財務データに限られるが、統計的手法によるデータリンケージを用いて多種のデータベースをリンケージすれば、別の側面から見た銀行や企業の属性別の結果を得ることや、より普遍的な結果を得ることが可能になると考えられる。

## 第4章

# 企業ミクロデータ構造化のための マッチング確率を用いた重み付き 2部グラフの最適マッチング手法 の検証

### 4.1 導入

金融政策の波及効果をミクロデータで検証するにあたって、第2章と第3章の研究では、分析対象のデータの企業規模が限られること、また、大企業の中でも上場企業に限られることで生じる偏りには焦点をあてなかった。しかし本来は、データに中小企業を含み、全数調査あるいは標本理論に基づくデータであることが望ましい。また、政策立案の観点からは、金融政策が銀行の資金供給や企業の資金需要に影響を与えたか否かに加えて、企業の資金需要が投資目的といった前向きな資金需要であるかどうかに関心があることから、こうした関心に答える調査項目があることが望ましい。

第4章では、民間データである日経 NEEDS 社 FinancialQUEST の企業財務データベースと、公的データである経済産業省企業活動基本調査を、統計的マッチング手法と、重み付き2部グラフの組み合わせ最適化アルゴリズムを用いてリンケージさせる。これらのデータを用いても、企業規模は大企業に限られるが、先行研究が行った中小企業への適用事例と併せて検討することで、同手法が企業データに安定的に適用できるかを検証する。また、経済産業省企業活動基本調査のミクロデータからは、企業が銀行から調達した資金をどのように運用しているかについての情報を得ることができる。また、統計的マッチング手法を適用する際に、マッチングに用いる変数に工夫を加えるほか、計算したマッチング

確率を重みとした重み付き 2 部グラフの組み合わせ最適化アルゴリズムを複数比較して、マッチングの正解率を向上させる方法を検討する。

企業データの統計的マッチング手法としては、Takabe and Yamashita (2020) が提示した、データ間の距離に、多項ロジットモデルに基づいて計算したウェイトを用いて加重して類似度（マッチング確率）を測る手法が、正しいマッチング相手と高い精度でマッチングできることが示されている。この手法は、異なるデータベースに含まれる企業全ての組み合わせについてマッチング確率を計算するものであり、これを計算した後に、何らかの方法でどのレコードとどのレコードをマッチングさせるかを決定する必要がある。これは、マッチング確率を重みとした重み付き 2 部グラフの最適マッチングと捉えることができる。先行研究では、ハンガリー法を適用したレシピエント（本研究では経済産業省企業活動基本調査）側の重複なし（1 対 1）マッチングを推奨しているが、本研究では、目的関数と制約条件に注目して複数のマッチング手法を比較して、レシピエント側の重複を許す 1 対多のマッチングが精度を向上させることを明らかにした。

### 分析 1 : 多項ロジットモデルを用いた統計的マッチングを大企業に適用

Takabe and Yamashita (2020) が提案した多項ロジットモデルに基づく統計的マッチング手法を用いて、経済産業省企業活動基本調査（以下、企活）と、日経 NEEDS 社 FinancialQUEST の企業財務データベース（以下、FQ）とをマッチングする。企活は、企業の投資額だけではなく、投資地（国内／海外）や投資目的（研究開発投資、技術の所有と取引等）等も調査している。また、2 章で行ったように、FQ は完全照合によって金融機関借入データベースとリンクさせることが可能であり、企活と FQ のマッチングを適切に行うことができれば、金融政策の波及効果についてより具体的な関心にこたえる分析が可能になる。

Takabe and Yamashita (2020) が帝国データバンクと経済センサスという、主に中小企業を対象に行った先行研究では、マッチング確率には、業種、住所、設立年といったカテゴリカル変数の情報が大きく影響するという結果であったことから、本研究では、先行研究と異なって設立年を 4 分類にするのではなくそのまま用いたほか、住所についても地域区分ではなく郵便番号をそのまま用いたところ、大企業を対象にしているという違いがあるものの、マッチングの正解率において 9 割を超える精度を達成できた。また、先行研究が、マッチング確率 1 位、1 位から 2 位、1 位から 3 位という順に、正しいマッチング相手が含まれる確率を

並べると、1位から20位までに向けて徐々に高まっていくのに対して、本研究ではマッチング確率1～2位で正解率約9割を達成した。

## 分析2: 重み付き2部グラフの組み合わせ最適化アルゴリズム比較

分析1で計算した、企活とFQの全ての企業の組み合わせについてのマッチング確率を重みとみなして、重み付き2部グラフの組み合わせ最適化問題を解いて最終的なマッチングを決定する。これにあたって、目的関数を何とするか、レシピエント側の重複を許さない「1対1」の制約付きマッチングとするか、重複を許す「1対多」のマッチングとするかの観点から、先行研究が勧めるハンガリー法とGale-Shapleyの安定結婚問題、Gale-Shapleyの大学入学問題アルゴリズム、整数線形計画法のソルバーによる推定で正解率を比較した。この結果、目的関数がいずれであっても正解率に違いはないが、重複を許す1対多のマッチングの正解率がより高いことを明らかにした。

## 4.2 先行研究と課題

### 4.2.1 多項ロジットモデルによる統計的マッチングの先行研究と課題

Takabe and Yamashita (2020) では、民間データである帝国データバンクのマイクロデータと、公的データである経済センサス活動調査のマイクロデータを使用してマッチングを行い、従来の研究で用いられてきた最近隣法 (Gower 距離及び Mahalanobis 距離) によるマッチングよりも高い精度を達成している。但し、データの属性としては、資本金額が300万円以上5000万円未満とそれほど規模が大きくない、実態としては中小企業が多いデータを対象としており、大企業への適応は未検証である。また、使用した変数は両方のデータベースに共通して存在する6変数 (従業者数、売上高、資本金額、産業大分類、開設年、地域) としており、これらの変数が他のデータについても適切であるかどうかは未検証である。

#### 4.2.2 重み付き2部グラフの組み合わせ最適化を用いたマッチングの先行研究と課題

Takabe and Yamashita (2020) では、マッチングの対象とした帝国データベースの企業と、経済センサス活動調査の企業の全ての組み合わせについてマッチング確率を計算した後に、最終的なマッチングを決定する際、レコードが複数回使用されるとマッチングの精度が低下するおそれがあるとして、レコードの使用回数に1回という制約を付した1対1のマッチングを行うハンガリー法の使用を推奨している。しかし、この制約を加えると、アルゴリズムに従って一度ある帝国データベースの企業にマッチングされた経済センサスの企業は、他の帝国データベースの企業にマッチングされることがないため、真のマッチング相手が別の帝国データベースの企業だった場合、帝国データベースの企業が2社ともマッチング相手を誤ることになる。これに対して、1対多として2回までの重複を許すと、一度他の帝国データベースの企業にマッチングされた経済センサスの企業を、重複して別の帝国データベースの企業にマッチングさせることができるため、帝国データベースの企業のうち片方は誤ったマッチング相手となるものの、もう片方は真のマッチング相手とマッチングされるケースが生じうる。従って、1回の制約条件付きマッチングと重複を許すマッチングとで、どちらの正解率が高いかは先験的には分からない。

また、どのような目的関数を最適化するかについても検討する余地がある。自然な選択肢は、全体のマッチング確率とマッチング数を最大化する最大重み最大マッチングであるが、もう一つの選択肢として、Gale-Shapley(Gale and Shapley, 1962)が提唱した安定的マッチングがある。安定したマッチングとはブロッキングペアが存在しない状況を指す。データリンケージにおいて不安定なマッチングが存在すること自体は問題ないが、Gale-Shapley アルゴリズムの独自の遅延受け入れアルゴリズムに基づいて別の解を与える可能性があることから、いずれの正解率が高いか比較する。

## 4.3 多項ロジットモデルによるマッチング確率の推計

### 4.3.1 類似度を測る距離

本項では Takabe and Yamashita (2020) が提案する多項ロジットモデルを用いる前提となる類似度を測る距離の種類について説明する。統計的マッチングを行うためにデータ間の類似度を測る方法には下記のような距離がある。

図表 14 距離の定義に用いる記号の意味

記号	意味
$i, j$	各データベースに含まれるレコード（調査客体，本稿では企業）を表す添え字（ $i$ と $j$ が属するデータベースは別）
$k$	各データベースに含まれる共通変数を表す添え字
$p$	説明変数の数
$D_{i,j}$	レコード $i$ とレコード $j$ の距離
$\beta_k$	$k$ 番目の共通変数に係るウェイト
$X_{ik}$	レコード $i$ に含まれる $k$ 番目の共通変数
$X_{jk}$	レコード $j$ に含まれる $k$ 番目の共通変数
$\Sigma_{XX}$	共通変数の分散共分散行列
$R_k$	$k$ 番目の共通変数の最大値と最小値の差

絶対値距離（マンハッタン距離）：

$$(4.1) \quad D_{ij} = \sum_{k=1}^p \beta_k |X_{ik} - X_{jk}|$$

ユークリッド距離（2乗）：

$$(4.2) \quad D_{ij} = \sum_{k=1}^p \beta_k (X_{ik} - X_{jk})^2$$

Mahalanobis 距離 :

$$(4.3) \quad D_{ij} = (X_{ik} - X_{jk})^T \Sigma_{XX}^{-1} (X_{ik} - X_{jk})$$

カテゴリカルデータに関する距離 :

$$(4.4) \quad D_{ij} = \sum_{k=1}^p \beta_k I(X_{ik} = X_{jk})$$

$I(X_{ik} = X_{jk})$ は以下で定義される関数

$$I(X_{ik} = X_{jk}) = \begin{cases} 1(X_{ik} = X_{jk}) \\ 0(X_{ik} \neq X_{jk}) \end{cases}$$

Gower 距離 :

$$(4.5) \quad D_{ij} = \frac{1}{p} \sum_{k=1}^p D_{ijk}$$

$D_{ijk}$ は以下で定義される関数

$X_{ik}$ と $X_{jk}$ が連続変数の場合

$$D_{ijk} = \frac{|X_{ik} - X_{jk}|}{R_k}$$

$X_{ik}$ と $X_{jk}$ が離散変数の場合

$$D_{ijk} = I(X_{ik} = X_{jk})$$

$R_k$ は、 $k$ 番目の共通変数のレンジ（最大値－最小値）を表す。

### 4.3.2 多項ロジットモデルを用いた統計的マッチングのモデル

多項ロジットモデルを用いた統計的マッチング (Takabe and Yamashita, 2020) では、前項に示したような距離そのものを類似度として用いるのではなく、多項ロジットモデルを用いて教師あり学習を行い、変数毎の距離のウェイトを推計して、距離に加重したマッチング確率を計算して類似度とする。本節ではマッチング確率を推定するモデルを説明する。



FQ のレコード（企業）数を  $M$ 、企活のレコード（企業）数を  $N$  とすると、多項ロジットモデルを用いた統計的マッチング手法では、前項で示したようなデータ間の距離  $D_{ij}$  に基づいて、下記で表されるような、FQ のある企業  $i (1 \leq i \leq M)$  に対して、企活のある企業  $j (1 \leq j \leq N)$  が正しいマッチング先である確率（マッチング確率）  $P_{ij}$  を計算する。

$$(4.6) \quad P_{ij} = \frac{\exp(-D_{ij})}{\sum_{j=1}^N \exp(-D_{ij})}$$

全てのレコード ( $i$  と  $j$ ) の組み合わせについて距離  $D_{ij}$  を計算すれば、上式に基づいて各組み合わせに対するマッチング確率  $P_{ij}$  を計算することができる。

#### 4.3.3 多項ロジットモデルを用いた統計的マッチングにおけるウェイト推定

前項で示したように、マッチング確率  $P_{ij}$  は、距離と、距離のウェイトを用いて計算する、距離のウェイトとなる多項ロジットモデルの説明変数の係数  $\beta = (\beta_1, \beta_2, \dots, \beta_p)$  は、最尤法を用いて推定する。対数尤度関数  $l(\beta_1, \beta_2, \dots, \beta_p)$  は、マッチング確率  $P_{ij}$  を用いて下記で表される。

$$(4.7) \quad \begin{aligned} l(\beta_1, \beta_2, \dots, \beta_p) &= \log \left( \prod_{i=1}^M \prod_{j=1}^N P_{ij}^{\delta_{ij}} \right) \\ &= \sum_{i=1}^M \sum_{j=1}^N \delta_{ij} \log(P_{ij}) \\ &= \sum_{i=1}^M \sum_{j=1}^N \delta_{ij} \left[ -D_{ij} - \log \left( \sum_{j=1}^N \exp(-D_{ij}) \right) \right] \end{aligned}$$

$\delta_{ij}$  は以下で定義される関数

$$\delta_{ij} = \begin{cases} 1 & (\text{企業 } i \text{ と企業 } j \text{ が同一である場合}) \\ 0 & (\text{企業 } i \text{ と企業 } j \text{ が異なる場合}) \end{cases}$$

#### 4.3.4 分析に用いるデータ

FQと企活の、2018年、2017年、2016年の各年の調査を用いた。両調査の詳細については以下を参照。

##### 日経 NEEDs 社 FinancialQUEST (FQ)

- 有価証券報告書、決算短信、決算発表資料等の開示資料及び日経独自調査から財務関連データを収録。
- 収録対象企業は、JASDAQを含む全国証券取引所の上場会社（上場廃止を含む）。
- 約3千社。

##### 経済産業省企業活動基本調査（企活）

- 経済産業省が所管する、企業の活動の実態を明らかにすることにより、企業に関する施策の基礎資料を得ることを目的に行われる調査。
- 母集団名簿は事業所母集団データベース。
- 抽出方法は全数調査。約4万社、
- 回収率は約9割
- 調査対象は全国の日本標準産業分類の次に掲げる業種の事業所を有する企業のうち、従業員50人以上かつ資本金または出資金3,000万円以上の企業。
  - ①大分類 C－鉱業、採石業、砂利採取業
  - ②大分類 E－製造業
  - ③大分類 F－電気・ガス・熱供給・水道業（中分類 35 熱供給業及び中分類 36 水道業を除く）
  - ④大分類 G－情報通信業
  - ⑤大分類 I－卸売業、小売業
  - ⑥大分類 J－金融業、保険業
  - ⑦大分類 K－不動産業、物品賃貸業
  - ⑧大分類 L－学術研究、専門・技術サービス業
  - ⑨大分類 M－宿泊業、飲食サービス業
  - ⑩大分類 N－生活関連サービス業、娯楽業
  - ⑪大分類 O－教育、学習支援業

## ⑫大分類 R-サービス業（他に分類されないもの）

距離の計測に用いる変数として、FQ と企活に共通する調査項目のうち、Takabe and Yamashita (2020) に倣って下記 6 つの変数を使用した。なお、先行研究では設立年が 4 区分のカテゴリカル変数となっているのに対して、本データは設立年そのものをカテゴリカル変数として用いている。また、先行研究では所在地について市または郡に応じた地域区分をカテゴリカル変数として用いているのに対して、本データは郵便番号をカテゴリカル変数として用いている。また、6 変数について欠測値がないレコードのみを分析対象とした。

- 1) 従業員数
- 2) 資本金
- 3) 売上高
- 4) 標準産業分類（カテゴリカル変数）
- 5) 設立年（カテゴリカル変数）
- 6) 所在地の郵便番号（カテゴリカル変数）

教師あり学習を行うために、あらかじめ名前と所在地等に基づいて正しいマッチング相手を特定した。この際、FQ については完全照合できなかったレコードを分析対象から除外した。このため、FQ については全てのレコードについて企活の正しいマッチング相手が存在する。従って、マッチング元が FQ（ドナー）であり、マッチング先（レシピエント）が企活である。その後、これらの完全照合キーを削除した。

こうして準備したデータのレコード数は、2016～2018 年平均で FQ 約 1,000 社、企活約 22,000 社である。これらを学習用データセットとしてランダムに 3/5 を抽出し、残りの 2/5 をモデルの性能を検証するためのテスト用データセットとした。

図表 15 学習データとテストデータのレコード数

	2016 年	2017 年	2018 年
(1) 学習データ	13,413	13,984	14,728
FQ データ	547	668	652
企活データ	12,866	13,316	14,076
(2) テストデータ	8,944	9,324	9,820
FQ データ	366	446	436
企活データ	8,578	8,878	9,384
(1)+(2)	22,357	23,308	24,548

#### 4.3.5 分析に用いる多項ロジットモデル

本分析で用いるデータは、連続変数とカテゴリー変数の両方を用いるため、多項ロジットモデルに用いる距離は、(4.1) 式及び (4.4) 式を組み合わせた以下の (4.8) 式で表される距離を用いる。(4.8) 式に含まれる記号の定義は図表 16 の通りである。また、関数  $I(S_i = S_j)$  などの定義については、(4.4) 式と同様である。

$$(4.8) \quad D_{ij} = \beta_1 |X_i - X_j| + \beta_2 |Y_i - Y_j| + \beta_3 |Z_i - Z_j| + \beta_4 I(S_i = S_j) + \beta_5 I(O_i = O_j) + \beta_6 I(R_i = R_j)$$

図表 16 距離関数に含まれる記号の定義

記号	意味
$i$	FQ のレコードを表す添え字
$j$	企活のレコードを表す添え字
$X_i, X_j$	従業員数 (人)
$Y_i, Y_j$	売上高 (百万円)
$Z_i, Z_j$	資本金額 (百万円)
$S_i, S_j$	産業分類 (大分類)
$O_i, O_j$	設立年
$R_i, R_j$	郵便番号
$\beta_1, \beta_2, \beta_3, \beta_4, \beta_5, \beta_6$	各共通変数のウェイト

なお、距離のウェイトを推計する際には 2 通りのデータの使い方が考えられる。すなわち、(a) FQ から見たデータセット (応答変数が企活の

レコード数ある)と(b)企活から見たデータセット(応答変数がFQのレコード数ある)である。両者の違いは距離のウェイトの違いとなって現れる可能性があるが、次項では(a)について述べる。なお、重み付き2部グラフの組み合わせ最適化によるマッチングでは(a)と(b)両方を用いる方法も比較して検討する。最尤推定には、統計分析ソフトRのoptimパッケージ(準ニュートン法)を用いた。

#### 4.3.6 多項ロジットモデルの推定結果

ユークリッド距離(対数変換値)、絶対値距離、絶対値距離(対数変換値)で測った距離を用いて多項ロジットモデルの推定結果を示したものが、図表17である。比較対象として、Takabe and Yamashita (2020)で中小企業について推計した結果の一部を図表18として掲載した。抜粋掲載したのは、先行研究が地域別に作成した3つのデータセットのうち一つ(データセットA,B,CのうちA)に対する推定結果で、その他の地域(データセットB,C)についても同様の結果が得られている。

図表 17 多項ロジットモデルの推定結果

2018 年

変数	ユークリッド距離(log)	絶対値距離	絶対値距離(log)
従業員数	-0.135 (-2.425)	-0.983 (-2.098)	-0.275 (-2.449)
資本金	0.414 *** (10.437)	0.707 ** (5.309)	0.839 *** (10.480)
売上高	0.175 ** (4.946)	0.059 *** (31.599)	0.344 ** (4.802)
産業大分類	1.403 ** (4.153)	1.978 ** (8.153)	1.398 ** (4.136)
設立年	3.949 *** (10.731)	5.147 *** (20.555)	3.95 *** (10.742)
郵便番号	8.401 *** (22.987)	9.443 *** (34.025)	8.395 *** (22.961)
対数尤度 (Log-likelihood)	-242.87	-469.26	-242.62
疑似 R2 乗	0.930	0.867	0.930

\*\*\*  $p < 0.001$ , \*\*  $p < 0.01$ , \*  $p < 0.05$ , .  $p < 0.1$ 

(): tvalue of each coefficient

2017 年

変数	ユークリッド距離(log)	絶対値距離	絶対値距離(log)
従業員数	-0.103 (-1.388)	1.146 ** (5.709)	-0.217 (-1.432)
資本金	0.422 *** (8.418)	1.758 ** (6.192)	0.852 *** (8.462)
売上高	0.35 ** (8.002)	0.099 *** (29.761)	0.703 ** (7.891)
産業大分類	1.339 ** (3.338)	1.817 ** (7.784)	1.339 ** (3.335)
設立年	2.761 ** (5.528)	5.282 *** (20.512)	2.757 ** (5.516)
郵便番号	9.265 *** (19.233)	9.138 *** (33.735)	9.251 *** (19.237)
対数尤度 (Log-likelihood)	-160.92	-496.68	-161.11
疑似 R2 乗	0.955	0.864	0.955

\*\*\*  $p < 0.001$ , \*\*  $p < 0.01$ , \*  $p < 0.05$ , .  $p < 0.1$ 

(): tvalue of each coefficient

2016 年

変数	ユークリッド距離 (log)	絶対値距離	絶対値距離 (log)
従業員数	-0.116 (-1.670)	1.760 (5.189)	-0.236 (-1.673)
資本金	0.55 (11.291)	0.01 (0.744)	1.118 (11.261)
売上高	0.213 (4.473)	0.06 (0.000)	0.421 (4.329)
産業大分類	1.745 (3.814)	3.045 (10.283)	1.739 (3.791)
設立年	1.871 (3.215)	5.157 (20.265)	1.855 (3.175)
郵便番号	8.679 (16.920)	9.091 (33.071)	8.674 (16.871)
対数尤度 (Log-likelihood)	-140.63	-431.91	-140.16
擬似 R2 乗	0.952	0.857	0.952

\*\*\*  $p < 0.001$ , \*\*  $p < 0.01$ , \*  $p < 0.05$ , .  $p < 0.1$ ( ):  $t$ value of each coefficient

図表 18 Takabe and Yamashita(2020)での中小企業についての推計結果(3地域にわけたデータセットのうち一つに適用した結果)

変数	ユークリッド距離	絶対値距離	絶対値距離 (対数)
従業員	0.115 (8.843)	1.406 (31.318)	1.117 (46.683)
資本金額	0.127 (18.333)	0.371 (49.358)	0.802 (73.574)
売上高	0.015 (4.428)	0.392 (28.280)	0.786 (61.456)
産業	3.684 (82.557)	3.535 (77.175)	3.472 (73.665)
設立年	1.465 (46.514)	1.366 (41.239)	1.318 (37.783)
地域(市・区)	9.053 (22.142)	9.625 (18.935)	9.018 (22.021)
会社の種類(株式会社/有限会社)	4.203 (33.352)	3.749 (28.487)	3.957 (28.910)
対数尤度 (Log-likelihood)	-25742	-19993	-15319
擬似 R2 乗	0.444	0.568	0.669

\*\*\*  $p < 0.001$ , \*\*  $p < 0.01$ , \*  $p < 0.05$ , .  $p < 0.1$ ( ):  $t$ value of each coefficient

マッチング確率を表す(4.6)式で距離 $D_{ij}$ にマイナスがかかっていることから、距離が小さければマッチング確率が上がるとすると、係数は全てプラスであると想定される。先行研究の結果によると、中小企業については全ての $t$ 値が十分に大きく、ほぼ全ての係数が99%の有意水準で有

意であった。特に、産業分類と地域の係数は他の変数よりも高い値を示しており、これらのカテゴリカル変数がモデルによって推定されたマッチング確率に強い影響を与えている。本項で推定した結果によると、大企業も中小企業と同様にカテゴリカル変数の $t$ 値が大きい傾向にある。特に郵便番号は、大企業についてはそれだけで住所を特定できることもあるため、マッチング確率に強い影響を与えたと考えられる。連続変数については、2016年データの資本金額と売上高の係数など、有意でない $t$ 値があった（絶対値距離）。また、従業員数の係数の符号がマイナスになるものがあった（ただし $t$ 値が有意でない）。これは、中小企業のデータよりも値が大きい大企業のデータを用いた推計結果が、外れ値の影響を受けやすい傾向にあるためと考えられる。

中小企業の推計結果と大企業の推計結果とも、擬似 $R^2$ の値から、対数変換した重み付き絶対距離が最もデータに対してフィットしていることがわかる。擬似 $R^2$ を比較すると、対数変換した距離を用いたモデルの方がデータへの適合性が高い。

#### 4.3.7 複数手法のマッチング精度比較

本項では、前項で推計した距離のウェイトを用いて、テストデータについてマッチング確率を推定し、ウェイトを用いない最近隣法も含めた複数のマッチング手法についてマッチング精度を比較する。マッチング精度は下式で定量的に評価する。これはマッチング元（ドナー）の各レコードについて、マッチング確率の高い上位  $R$  件の候補レコードに正しいマッチング先が含まれる割合を算出するものである。

FQにおけるテストデータの各レコード $i$  ( $i = 1, 2, \dots, M_{test}$ )に対して、企活のテストデータにおいて対応する正しいレコードのインデックスを $t_i$ とする。  $i$ に対して、企活のテストデータのレコードについて、マッチング確率が高かった順に上位  $R$  件のレコードを取り出し、その集合を $C(i, R)$ とする。このとき、 $t_i$ が上位  $R$  件の候補レコードに含まれている割合（正解率） $P(R)$ は、以下の式(4.9)で表される。

$$(4.9) \quad P(R) = \frac{1}{M_{test}} \sum_{i=1}^{M_{test}} I(t_i \in C(i, R))$$

$C(i, R)$ は、以下のように表される関数である。



$$I(t_i \in C(i, R)) = \begin{cases} 1 & (t_i \in C(i, R)) \\ 0 & (t_i \notin C(i, R)) \end{cases}$$

比較するのは、下記の 5 つの距離を用いて計算した  $P(R)$  である。

- 1) 多項ロジットモデルによる加重絶対値距離
- 2) 多項ロジットモデルによる加重絶対値距離 (対数変換値)
- 3) 多項ロジットモデルによる加重ユークリッド距離 (対数変換値)
- 4) Mahalanobis 距離
- 5) Gower 距離

図表 19 の横軸は、マッチング確率上位 1 位から 20 位までを意味する。縦軸は、対応する正解率  $P(R)$  である。比較対象として、Takabe and Yamashita (2020) で中小企業について推定した結果の一部を図表 20 として掲載した。抜粋掲載したのは、先行研究が地域別に作成した 3 つのデータセットのうち一つ (データセット A, B, C のうち A) に対する推定結果で、その他の地域 (データセット B, C) についても同様の結果が得られている。図表 21 は、上位 1 位の正解率をまとめたものである。比較対象として、Takabe and Yamashita (2020) で中小企業について推定した結果を図表 22 として掲載した。

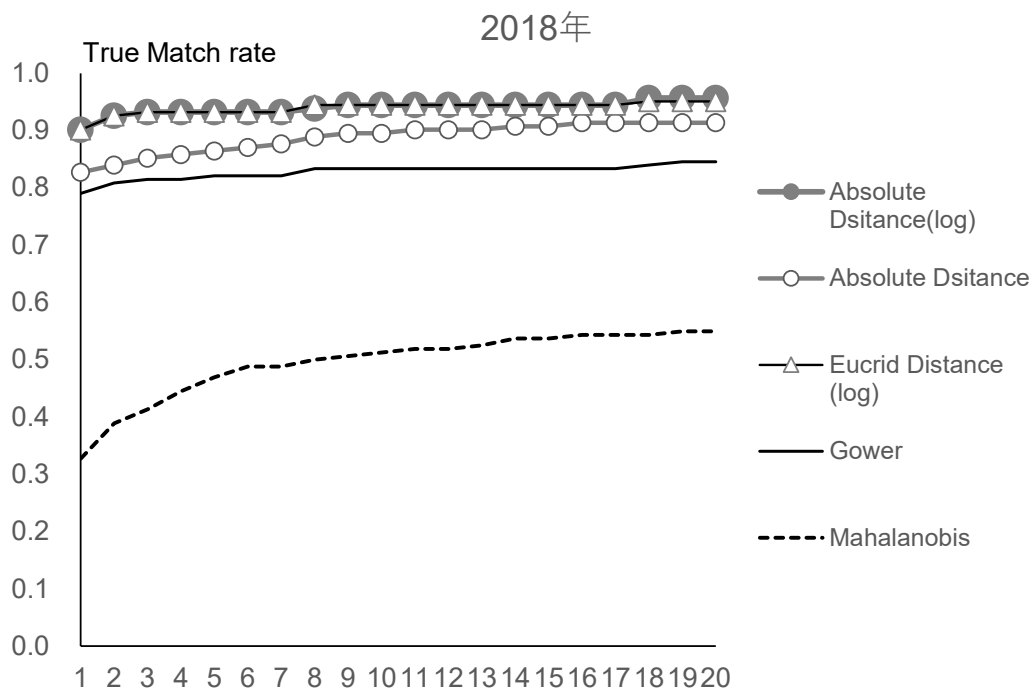
図表 19 と図表 20 のグラフの形状を比較すると、大企業は中小企業よりも上位 1 ~ 2 位に正しいマッチング相手が含まれる割合が高いことがわかる。

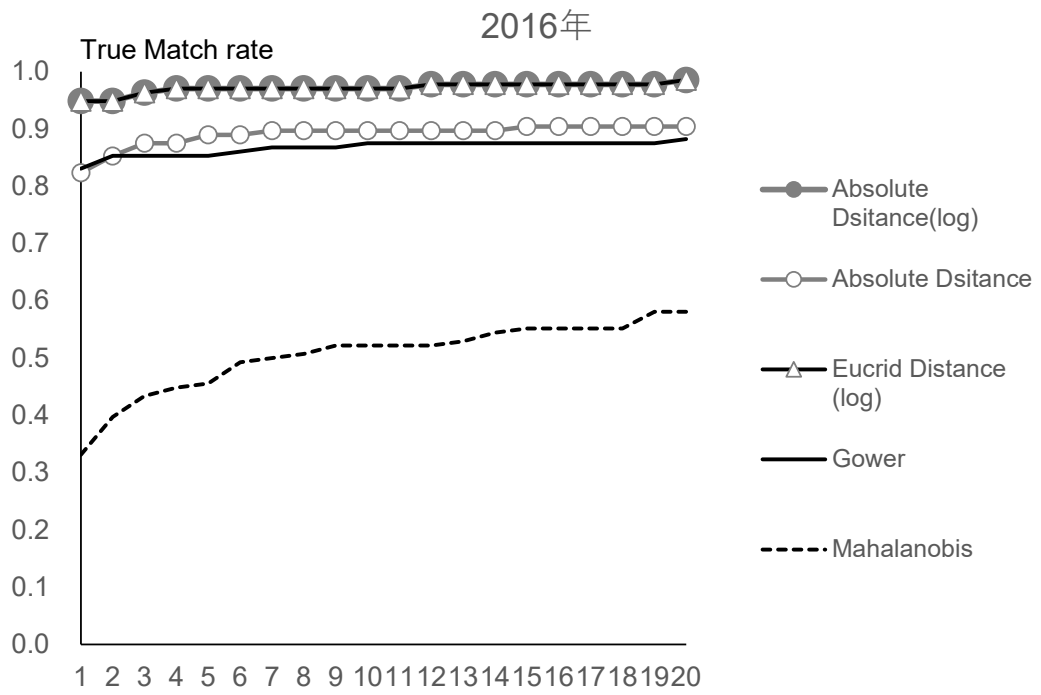
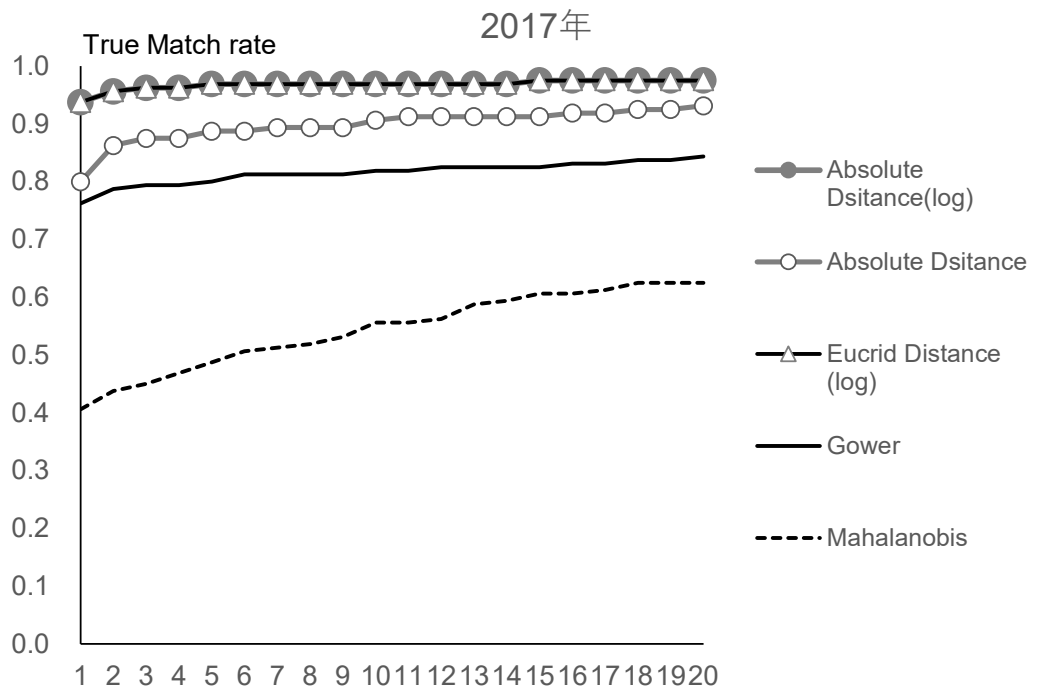
また、多項ロジットモデルに基づくウェイト付の加重距離を用いたマッチングは、先行研究と同様に、全ての年において、Gower 距離や Mahalanobis 距離に基づく単純な最近傍法と比較して正解率が高い。他方で先行研究とは異なり、同じ多項ロジットモデルに基づくマッチング確率の中では、絶対値距離 (対数変換値) に基づくものとユークリッド距離 (対数変換値) に基づくものとは、正解率の違いはほとんどなかった。これに対して、同じ絶対値距離によるものでも、対数変換値はより高い正解率となった。これは、大企業については距離の測り方よりもレコード間の小さな距離を拡大して捉えることが、正解率に大きな影響を与えることを示している。

図表 21 と図表 22 を比較すると、大企業についての正解率の水準の高さがわかる。これらの結果から、次節で行う重み付き 2 部グラフの組み

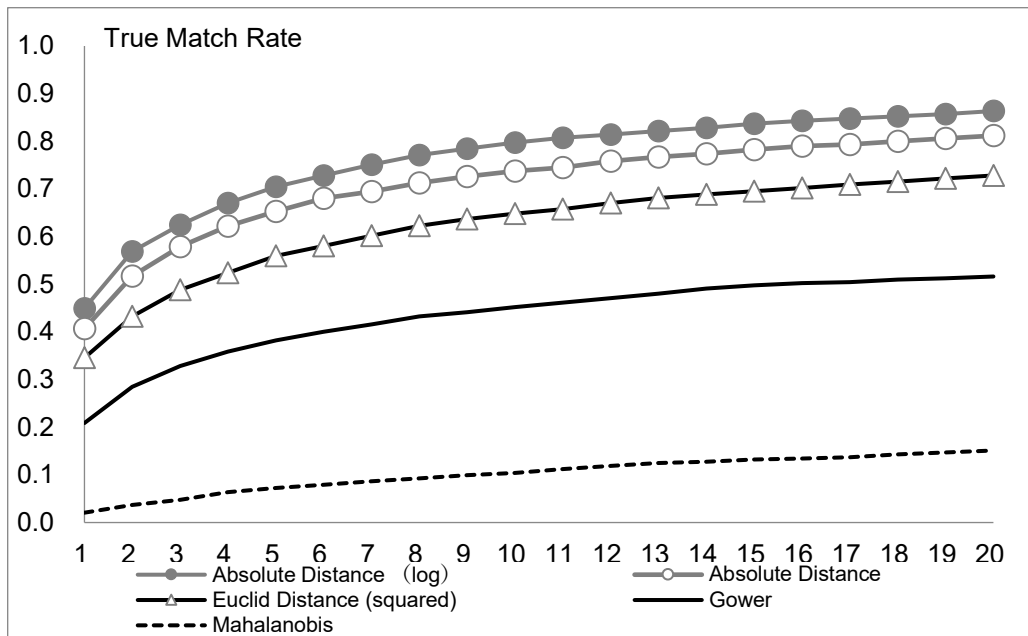
合わせ最適化によるマッチングでは，中小企業についても大企業についても最も高い正解率を出した絶対値距離（対数変換値）を用いて多項ロジットモデルで推計したマッチング確率を用いる．

図表 19 マッチング正解率比較





図表 20 Takabe and Yamashita(2020)での中小企業についての推計結果(3地域にわけたデータセットのうち一つに適用した結果)



図表 21 上位1位の正解率

	2018	2017	2016
多項ロジットモデルによるウェイト付			
加重ユークリッド距離(対数2乗)	0.901	0.938	0.949
加重絶対距離	0.827	0.800	0.824
加重絶対値距離(log)	0.901	0.938	0.949
最近隣法			
Mahalanobis 距離	0.327	0.406	0.331
Gower 距離	0.790	0.763	0.831

図表 22 Takabe and Yamashita (2020)での中小企業についての推計結果

	データA	データB	データC
多項ロジットモデルによるウェイト付			
加重ユークリッド距離(2乗)	0.346	0.463	0.243
加重絶対距離	0.407	0.528	0.350
加重絶対距離(log)	0.449	0.582	0.390
最近隣法			
Mahalanobis 距離	0.021	0.092	0.030
Gower 距離	0.209	0.367	0.220

## 4.4 マッチング確率を重みとした2部グラフの最適マッチングのアルゴリズム比較

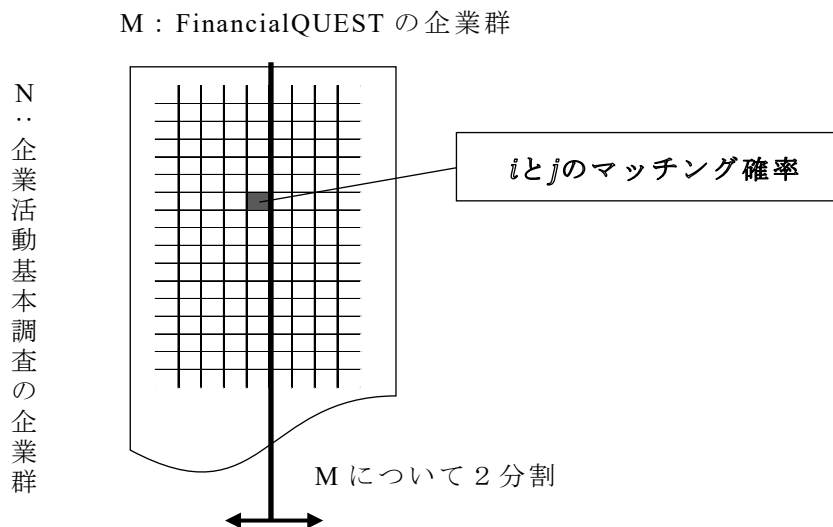
本節では、前節で計算した全てのレコード同士の組み合わせのマッチング確率から、最終的にどの FQ レコードとどの企活レコードをマッチングさせるかという問題を、重み付き 2 部グラフの最適マッチングとして考えて、重み付き 2 部グラフの最適マッチングのためのアルゴリズムを正解率で比較する。

### 4.4.1 分析に用いるデータ

2018 年の FQ と企活のテストデータについて絶対値距離(対数変換値)を用いて多項ロジットモデルで計算したマッチング確率を重みとする。

テストデータは  $M=436$  レコード、 $N=9,384$  レコードからなる。学習データとテストデータとを合わせると全ての  $M$  について  $N$  のうちに正しいマッチング相手が含まれていたが、学習データとテストデータにランダムに分ける際に入れ練りが生じているため、テストデータに含まれる正しいマッチングペアは 162 ペアである。また、整数線形計画問題をソルバーで解く際に、入力サイズが大きすぎて扱いが容易な時間では計算を実行できなかったため、テストデータを 2 分割 (データ A とデータ B) して使用した。この際、 $M$  について 2 分割しており、各  $i$  について相手となりうる  $j$  は全社揃っている (図表 23 参照)。組み合わせ最適化は全体最適を行うため、全データを使うのと半分のデータを使うのとでは、同じ手法でもマッチング相手が異なる結果となる可能性はある。しかし、手法のパフォーマンス比較を行う上では同一条件である。分割したデータのうち、データ①は  $M=218$  社、 $N=9,384$  社、真のペアが 83 ペア含まれる。データ②は  $M=218$  社、 $N=9,384$  社、真のペアが 79 ペア含まれる。これに加えて、ソルバー以外のアルゴリズムについては分割しない全体データを使用した場合についても推定している、

図表 23 使用するデータのイメージ



#### 4.4.2 比較するアルゴリズム

本節では、重み付き2部グラフの組み合わせ最適化問題を、ハンガリー法、Gale-Shapley、整数線形計画法のソルバーの3種類のアルゴリズムを用いて解いた。比較するアルゴリズムとしてこれらを選択したのは、下記2つの点からである。

##### 各レコードがマッチングに使用される回数の制約

統計的マッチングは、各レコードがマッチングに使用される回数によって2つのタイプに分類される (Jaro, 1989; Rässler, 2002; D'Orazio et al., 2006; Goel and Ramalingam, 2012)。

- ・ 無制限マッチング

データに含まれるレコードがマッチングされる回数に制限のない方法 (同じレコードが複数回マッチングされる可能性がある)。本研究では、レシピエント (企活) 側のレコードに限ってマッチングされる回数が複数回であることを許すケースを指す。

- ・ 制約条件付きマッチング

データに含まれるレコードは、マッチングに1回しか使用できないという制約があるマッチング。

ハンガリー法と Gale-Shapley の安定結婚問題は、目的関数が異なる、1対1の制約付きマッチングである。Gale-Shapley の大学入学問題と、整数線形計画法のソルバーによるマッチング数の上限制約付き推定は、目的関数が異なる1対多のマッチングである。なお、本研究では企活レコードについてのみ無制限のマッチングを行うため、1対多の意味は、1つの企活レコードは複数の FQ レコードとのマッチングを受け入れるという意味である。FQ レコードが複数の企活レコードとマッチングされるわけではないため、1対多であるから正解率が向上するということはない。何回までの重複を許すかについては、仮に上限を2とした。前項で見た正解率は、ある1つの企活レコードが、FQ 側の複数のレコードにとってマッチング確率1位になった場合、その全ての FQ レコードに（マッチング確率が1位の）同じ企活レコードがマッチングされることをゆるしていることから、企活レコードについて上限なしで重複を許した場合の無制限マッチングの正解率にあたる。

1対1の制約を付けることの意義は、FQ（ドナー）と企活（レシピエント）を重複なくマッチングさせることができることである。欠点は、マッチング確率が最も高い相手とマッチングされないドナーやレシピエントが発生することである。これに対して、無制約マッチングは、各ドナーにとって最もマッチング確率が高い相手とマッチングさせることができるが、欠点は、複製されたレシピエントとマッチングされるドナーが発生することである。いずれの方法も、真のマッチング相手とマッチングされずに、マッチング後の分析において偏りを発生させる可能性がある。

そこで、本研究では偏りを生じさせない真のマッチングを実現したことを表す正解率を基準に、1対1の制約付きマッチングと、1対多の無制約マッチングを比較した。1対1の制約を加えると、アルゴリズムに従って、一度あるドナーにマッチングされたレシピエントは、他のドナーにマッチングされることがないため、最初にマッチングされた相手が真のマッチング相手でなかった場合、少なくとも2先のドナーがマッチング相手を誤る。また、この誤りが連鎖的に発生する可能性もある（最初にマッチングされた誤ったマッチング相手であるレシピエントが、元々、真のマッチング相手を持たないレコードであった場合は連鎖しない）。これに対して、1対多としてレシピエントの重複を許すと、真のマッチングペアは1組であるため、仮に重複したマッチングに正しいマッチングが含まれていたとしても、その1組を除いて誤ったマッチング



となる。1対1の制約条件付きマッチングと無制約マッチングとで、どちらの正解率が高いかは先験的には分からない。

なお、ハンガリー法と整数線形計画法のソルバーによる解法はマッチング確率をそのまま使用する。マッチング確率は距離を用いて計算することから、マッチングに使用する変数毎の距離が同程度の組み合わせは同程度のマッチング確率になる。従って、ドナーやレシピエント内に類似したレコードがあるケース以外にも、両者の距離が類似していれば、同程度のマッチング確率は発生しうる。Gale-Shapley アルゴリズムは、ドナー側とレシピエント側からみたマッチング確率の順位を使用する。元々、マッチング確率に使用する変数毎の距離について、近いマッチング候補がないドナーやレシピエントが存在する場合、水準で見たマッチング確率が高くなくとも順位では1位となり、他のレコードとマッチング相手が競合することが発生しうる。このように、ドナーやレシピエントのデータ分布から事前に優位なアルゴリズムを選定することは困難であり、実際の企業データを用いて検証する意義がある。

なお、前項で検証したように、上限無制約のマッチングで 90.1% という高い正解率を達成しているが、上限が無制限であれば、誤ったマッチングの全てが1つのレシピエントの複製マッチングである可能性も生じる。適用するアルゴリズムによって誤ったマッチングのありようは異なると考えられるが、アルゴリズム別のバイアスの評価については別途の検証が必要である。

前述したように、Gale-Shapley のアルゴリズムでは、FQ 側からのマッチング確率と企活側からのマッチング確率の両方を用いる。多項ロジットモデルによる距離のウェイトの推計は、 $N$ 個の応答変数を持つデータを用いて FQ ( $M$ ) 側からの重みを、 $M$  個の応答変数を持つデータを用いて企活 ( $N$ ) 側からの重みを算出することが可能で、両推定値は異なる可能性がある。また、アルゴリズムでは FQ ( $M$ ) 側優先のマッチングと企活 ( $N$ ) 側優先のマッチングが推定できることから、両者について推定した。なお、Gale-Shapley アルゴリズムは同じマッチング確率が存在することを許容していないため、同じ確率同士ではランダムにランク付けした。このため、単に互いが改善するだけでなく、他にペアがない相手である場合にブロッキングペアとみなす弱安定性を有するマッチングとなっている。なお、同確率のペアは2組存在した。

ハンガリー法の推定には、R の線形計画法計算用のパッケージ `clue` に含まれる関数 `solve_LSAP` を使用した。Gale-Shapley の推定には、R のマッチング用パッケージ `MatchingR` に含まれる関数

galeshapley.marriageMarket と galeshapley.collegeAdmissions を使用した。ソルバーによる推定には、Python の線形最適化用パッケージ PuLp を使用した。

### 整数計画問題の定式化

頂点集合  $V(G)$  が、FQ レコード  $A$  の頂点集合  $V(A)$  と、企活レコード  $B$  の頂点集合  $V(B)$  に分割できる 2 部グラフを想定する。

$$V(G) = V(A) \cup V(B)$$

$$|A| = M, \quad i(1 \leq i \leq M)$$

$$|B| = N, \quad j(1 \leq j \leq N)$$

グラフの辺の数  $|E(G)|$  は下記である。

$$|E(G)| = M \times N$$

各辺  $e \in E(G)$  の重みを、多項ロジットモデルで推計した、FQ のある企業  $i$  に対して、企活のある企業  $j$  が正しいマッチング先である確率（マッチング確率）  $P_{ij}(e)$  とする。

$x(e)$  を、辺  $e \in E(G)$  がマッチングに含まれるときに 1 をとる変数とする。FQ 側の頂点  $v \in V(A)$  に接している辺の集合を  $\delta(vA)$  とする。また、企活側の頂点  $v \in V(B)$  に接している辺の集合を  $\delta(vB)$  とする。

2 部グラフにおける最大重みマッチングに、FQ は必ず 1 先とマッチングし、企活は最大 2 先とマッチングするという制約を加えると、下記で表すことができる。

(4.10)

$$\begin{aligned} & \max_x \sum_{e \in E(G)} P_{ij}(e) x(e) \\ \text{subject to} & \sum_{e \in \delta(vA)} x(e) = 1, \quad \forall v \in V(A) \\ & \sum_{e \in \delta(vB)} x(e) \leq 2, \quad \forall v \in V(B) \\ & x(e) \in \{0,1\} \end{aligned}$$

#### 4.4.3 各アルゴリズムによる正解率比較

図表 24 各アルゴリズムの正解率

アルゴリズム	① ハンガリー法	② Gale-Shapley 安定結婚問題(1対1)M優先	③ Gale-Shapley 安定結婚問題(1対1)N優先	④ Gale-Shapley 大学入学問題(1対2)	⑤ ソルバー Mは最低1 のNと,Nは上限2のMとマッチング
データ A	0.867	0.867	0.867	0.880	0.880
データ B	0.924	0.924	0.924	0.924	0.924
全体	0.895	0.895	0.895	0.901	-

図表 24 は、各アルゴリズム（条件を変えたものを含む）で行ったマッチングの正解率をまとめたものである。1対1の制約付きマッチングである、ハンガリー法の①、Gale-Shapley 安定結婚問題（FQ 優先）の②、Gale-Shapley 安定結婚問題（企活優先）の③の正解率を見ると、1対1のマッチングの枠組み内では、目的関数がウェイト最大化であるか、安定マッチングであるかによって正解率に違いはない（データ A について 86.7%、データ B について 92.4%、全体について 89.5%）。なお、Lam et al. (2020) によると、目的関数を安定マッチングとした場合のマッチングの総ウェイトは、ハンガリー法の最適解に近く、データサイズが大きくなるにつれて 2 つのアルゴリズムの総ウェイトの差は小さくなる。また、Gale-Shapley 安定結婚問題において、FQ 優先か企活優先かで正解率に違いはなかった。

これら 1対1の制約付きアルゴリズムと、1対多のマッチングである、Gale-Shapley 大学入学問題の④及び整数線形計画問題をソルバーで解いた⑤とを比較すると、1対多アルゴリズムの真の一致率（90.1%）は、1対1アルゴリズム（89.5%）よりも高い。なお、前節で計算した、レシピエント側に無制限に重複をゆるした場合の正解率は 90.1%であったことから、正解率を上げるためには、上限を 2 にすれば十分であることがわかる。

#### 4.5 まとめと今後の課題

本研究では、企業マイクロデータの構造化のために、Takabe and Yamashita

(2020) が提示した多項ロジットモデルによる統計的マッチング手法を、民間データである日経 NEEDS 社 FinancialQUEST の企業財務データベースと、公的データである経済産業省企業活動基本調査に適用してリンケージを行った。使用する変数については、先行研究と同様に、カテゴリカル変数がマッチング確率に大きな影響を与えることがわかったことから、先行研究では設立年が 4 区分のカテゴリカル変数となっているのに対して、本研究は設立年そのものを用いたほか、先行研究では所在地について市または郡に応じた地域区分をカテゴリカル変数として用いているのに対して、本研究は郵便番号を用いるという変更を加えた。この結果、マッチング確率上位 1 位に正しいマッチング相手が含まれる確率が約 9 割と、精度を飛躍的に向上させた。また、マイクロデータ分析によって、企業が銀行から調達した資金をどのように運用しているか等、政策立案の立場からより具体的な関心に答えることが可能なデータを作成した。他方で、先行研究と異なり、連続変数である雇用者数については、マッチング確率を計算する際の距離のウェイトを推定するための教師あり多項ロジットモデルの推定において、統計的に有意でなかった。但し、同変数を取り込んだままでも約 9 割という高いマッチング精度を示した通り、先行研究が提示した 6 変数（売上高、資本金、雇用者数、設立年、所在地、標準産業分類）は、企業規模に関わらず、企業データのマッチングの際に安定的に用いることができると判断できた。

また、全てのレコードの組み合わせについてマッチング確率を推定した後、どのレコードとどのレコードをマッチングさせるかについて、マッチング確率を重みとした重み付き 2 部グラフの最適マッチングを考える際に、先行研究が 1 対 1 の制約付きハンガリー法アルゴリズムを推奨したのに対して、本研究では、目的関数と制約条件に着目して複数のアルゴリズムを比較検討した結果、レシピエント側の重複を許す 1 対多の Gale-Shapley 法アルゴリズムの方が、不正解となるマッチングの数を抑えて正解率を向上させることがわかった。なお、その場合でも上限はたかだか 2 で十分であることも明らかにした。但し、この結果はデータセットに依存すると考えられることから、企業数が多い中小企業データ等を用いて検証を重ねる必要がある。

今後の課題としては、今回の手法でマッチングしたデータを用いて、金融政策が企業の投資といった前向きな資金需要につながっているのかを分析し、政策的な関心への答えを得るとともに、企業マイクロデータ構造化が政策効果の研究に有用であることを明らかにすることである。

統計的マッチング手法についての今後の課題は、更に多くの企業デー

タへの適用事例を積み重ねるとともに、本研究のような教師あり学習ではなく、教師なし学習を考えることも有用である。また、構造化データの欠測値の取り扱いを検討することも有用である。本研究では、大企業の欠測値が相対的に少ないこともあり、欠測値があるデータを除外した。中小企業を中心に扱った先行研究では、欠測値を平均値で補って使用している。これに対して、欠測値が多いなどしてデータクオリティーが乏しい場合にも、似通ったデータをグループにまとめてマッチングする方法 (On et al., 2007) や、企業ではなく世帯の例であるが、過去の国勢調査を時系列でリンケージさせるために、世帯のメンバーを個々にリンケージさせるのではなく、世帯全体をリンクさせるなどの手法が提示されている (Fu et al., 2014)。また、多項ロジットモデルを用いたマッチング確率の正解率の高さを利用して、本分析が行った、レシピエント側の重複をゆるすマッチングを適用することも考えられる。他方で、無制約マッチングについては、正解率の上昇とバイアスの発生がトレードオフの関係になりうることから、適切な上限の設定を導くような指標を考えることも有用である。このように、同一の調査主体をマッチングさせることを想定したデータリンケージだけでなく、グルーピングを用いたデータリンケージや、更に進んで、異なるデータベースの異なる調査主体をマッチングさせることを想定したデータ融合の手法が、経済分野でも適用可能であることが明らかにできれば、分析の対象をかなり拡大できると考えられる。

## 第5章

# 総括

### 5.1 本研究の成果

本研究では、金融政策の波及効果をマイクロデータから検証した。分析のために、民間データの複数のデータベースを完全照合でマッチングして、分析に有用なデータを構築した。これによって、企業と銀行の財務データだけでなく、両者の取引を分析対象に含めることが可能となり、金融政策が各経済主体の意思決定にどのように影響していったか分析することを可能にした。

分析手法については、特に説明変数や交絡因子の選定、モデルの定式化の誤りに起因する推定値の偏りを避ける工夫がある、2つの分析を行った。一つ目の分析では、統計的因果推論の枠組みで、金融政策による介入の有無が企業の借入前年比に与える平均処置効果を推定した。平均処置効果を推定するためには、共変数を適切に選定し、それらを一次元に集約した傾向スコアを推定する必要があるが、その際、①傾向スコアを計算する際に利用する割り当て（金融政策の実施／非実施）と共変量のモデルが正しく指定されている、または、②共変量と被説明変数のモデルが正しく指定されている、のどちらかを満たせば、因果関係の一致推定量が得られるという、二重にロバストな推計と呼ばれる手法を用いることで、モデルの誤設定によって結果が偏るリスクを減らした。この結果、金融政策が企業のバランスシートを通じて波及する効果があることを示唆したが、借入前年比に及ぼす効果は、緩和であれ引き締めであれ、絶対値で1%にも満たない小さなものであることが示唆された。

二つ目の分析では、ランダムフォレストアルゴリズムによってデータ適合的なモデルを体系的に探索した後に、企業の借入前年比が増加したか否かを示す離散変数を被説明変数として、金融政策ショックに対する感度分析を行った。感度分析には、説明変数が被説明変数にどのように影響しているかを可視化した部分依存プロット（Partial Dependence Plot）と、金融政策とその他の変数の交互作用を可視化した2次元 Accumulated

Local Effects を用いて視覚的に分析して解釈した。この結果、一つ目の分析結果と同様に、金融政策の影響度合いは大きくないことと、銀行の資金供給よりも企業の資金需要を通じた影響が強いことがわかった。一方、金融政策は引き締めや緩和の水準や変化の幅というよりも、政策を転換したことが影響を与えている可能性があること、緩和的な金融政策下では規模が小さい銀行や流動性資産の保有率が低い銀行が企業向け融資をより活発に行う傾向が認められることが示唆された。

ところで、これらの分析に用いたデータは企業規模が大企業のうち上場企業に限られることや、調査項目が限られるといった制限がある。そこで、分析可能なデータを拡張するために企業マイクロデータの構造化を進めるべく、Takabe and Yamashita (2020) が提示した、データ間の距離に多項ロジットモデルに基づいて計算したウェイトを用いて加重して類似度（マッチング確率）を測る手法を、民間データである日経 NEEDS 社 FinancialQUEST の企業財務データベースと、公的データである経済産業省企業活動基本調査に適用した上で、マッチング精度の向上を図った。

精度向上のために、データ間の距離を測る変数に変更を加えた。先行研究を参考に、従業員数、資本金、売上高の3つの連続変数と、データ間で一致したか否かを0と1で表した標準産業分類、設立年、所在地の郵便番号の3つのカテゴリカル変数を使用した。この際、先行研究では設立年を4区分のカテゴリカル変数としたのに対して、設立年そのものを用いたほか、先行研究では所在地について市または郡に応じた地域区分をカテゴリカル変数としたのに対して、郵便番号そのものを用いた。この結果、先行研究が中小企業を、本研究が大企業を対象としているという違いはあるものの、マッチング確率1位が正しいマッチング相手である割合が9割という高い精度を達成した。

また、マッチングさせる全ての企業の組み合わせについてマッチング確率を計算した後に、これを重みとした重み付き2部グラフの最適マッチングを考える際に、先行研究では、マッチング確率を重みとした、重み付き2部グラフの最適マッチングと捉えて、ハンガリー法を適用したレシピエント側の重複なし（1対1）マッチングを推奨しているが、目的関数と制約について再検証する観点から、Gale-Shapley のアルゴリズムと、整数線形計画法を解く方法とも比較した。この結果、目的関数とは関係なく、レシピエント側の重複を許す1対多のマッチングが精度を向上させることを明らかにした。

このように、企業データに適用する統計的マッチング手法の適用可方法と精度改善方法を提示したことで、金融政策が銀行の資金供給、企業

の資金需要にどのような影響を与えるのか、影響があるとするれば、企業の資金需要は投資のような前向きな資金需要であるのか、政策立案の立場からみてより具体的な関心に答える分析が可能になったと考えている。

## 5.2 残された課題

本研究では、観察されたマイクロデータから金融政策効果を検証するために、これまでの手法が、モデルの誤設定に伴う偏りを回避できなかったのに対して、統計的因果推論の適用や、データ適合的なモデルを体系的に探索する機械学習の手法を取り入れて対応した。また、政策立案の立場からみて、より具体的な関心に答える分析が可能になるよう、企業マイクロデータの構造化に役立つ統計的マッチング手法の適用可能性と精度改善方法を提示した。しかし、経済分野におけるマイクロデータの分析のための課題は、分析手法と分析対象データの整備の両面においてまだ多く残されている。以下では、それらの課題と対応の方向性について述べる。

### 金融政策を表す変数の精緻化や説明変数の検討

本研究では、金融政策を引き締めか緩和かの離散データで表現したが、本研究の結果、金融政策は特に政策転換に意味があることが示唆された。このことから、複数の政策手段における政策変更のタイミングの情報を集約するような工夫の余地がある。また、金利の操作、量的緩和、アナウンスメント効果などの多様な政策手段をどのような変数で捉えているかは、離散変数か連続変数かといった問題よりも深刻な課題である。

### 被説明変数と説明変数の関係を明確にするための共変量の再検討

共変量の選定には、その分野に関する理論や、先行研究から得た知識が必要となるが、より探索的に探す方法を検討する余地がある。但し、共変量は、被説明変数と説明変数に関連する変数のうち、観測されているもの全てを用いると、推定値の分散が大きくなる可能性が高い。従って、金融政策の実施前変数であり、かつ被説明変数に先行する変数（共変量にするべき）と、実施後変数であり、かつ被説明変数に先行する変数（金融政策の介入効果を中間効果も含めてみる場合には共変量にするべき）と、金融政策の実施後変数であり、かつ被説明変数に後行する変



数（共変量にするべきでない）を慎重に見分ける必要がある。アベノミクスと呼ばれる量的緩和のブースティングによる株価上昇は、企業や銀行のリスクテイクに影響を及ぼした可能性がある。また近年は、コロナ感染症の世界的拡大によって世界的に経済活動が縮小した後、ウクライナにおける戦争がエネルギーや商品価格等を通じて世界的なインフレを起すなど、世界同時的なショックを受けて、大規模な金融緩和が世界各国でほぼ同時に導入されている。また、世界的な金融緩和の後に各国が固有の状況を踏まえて微妙な舵をとりながら金融引き締めへ転換している現状において、他国の金融政策の変更が為替や金利、金融その他商品価格を通じて日本経済に与える影響が大きい可能性がある。このことを考えると、海外の金融政策や金融市場の状況を取り込むなど、共変量を再検討するべきタイミングであると考えられる。

## 分析の拡充

第4章では、企業マイクロデータ構造化のための統計的マッチング手法の精度向上に焦点を当てたが、拡充したデータを分析に活用して、情報量が増えたデータを用いることの有用性を示していくことも重要な課題である。金融緩和によって資金調達が容易になった企業が、調達した資金をどのような用途に使ったか、金融システムの安定性の観点から、いずれかの銀行が破綻危機に陥った場合に、どの範囲に影響が及びうるのか、どのような銀行がどのような企業と取引する傾向があるか、銀行のリスクの取り方に偏りがいないか、等を把握する分析も政策立案の観点から有用であると考えられる。

## 5.3 今後の展望

多項ロジットモデルを用いた統計的マッチング手法は、モデルの推定を行うために完全照合を行うための正解データを必要とする。しかし、企業データに限れば、複数のデータへの適用事例を重ねていけば、ある程度安定したパラメータを得られる可能性がある。また、必ずしも同一の企業同士をマッチングさせることにこだわらず、似通ったグループごとマッチングさせる方法なども検討の余地がある。例えば、データクオリティーが乏しい場合に、似通ったデータをグループにまとめてマッチングする方法（On et al., 2007）や、過去の国勢調査を時系列でリンケー

ジさせるために、世帯のメンバーを個々にリンケージさせるのではなく、世帯全体をリンクさせる (Fu et al., 2014) などの手法が提示されている。この観点から、本分析が行った、マッチング確率を重みとした2部グラフの最適マッチングアルゴリズムを適用することも考え得る。このように、分野横断的に、様々な統計的マッチング手法やデータ融合の手法を組み合わせ、利用可能なデータを拡大してゆく必要があると考える。

以 上

## 参考文献

- Alessi, L. and Detken, C. (2018). Identifying Excessive Credit Growth and Leverage, *Journal of Financial Stability*, 35, pp.215-225.
- Apley, D. W. and Zhu, J. (2020) Visualizing the Effects of Predictor Variables in Black Box Supervised Learning Models, *Journal of the Royal Statistical Society Series B (Statistical Methodology)*, 82(4), pp.1059-1086.
- Athey, S. (2018). The Impact of Machine Learning on Economics, *The Economics of Artificial Intelligence: An Agenda*, (eds. A. Agrawal, J. Gans and A. Goldfarb), University of Chicago Press, Chicago, Illinois.
- Athey, S. and Imbens, G. W. (2017). The State of Applied Econometrics: Causality and Policy Evaluation, *Journal of Economic Perspectives*, 31(2), 3-32.
- Bang, H. and Robins, J. M. (2005). Doubly Robust Estimation in Missing Data and Causal Inference Models, *Biometrics*, 61(4), 962-973.
- Bernanke, B. S. and Gertler, M. (1995). Inside the Black Box: The Credit Channel of Monetary Policy Transmission, *Journal of Economic Perspectives*, 9(4), pp.27-48.
- Beutel, J., List, S. and von Schweinitz, G. (2019). Does Machine Learning Help us Predict Banking Crises?, *Journal of Financial Stability*, 45, 1100693.
- Breiman, L. (2001a). Random Forest, *Machine Learning*, 45, 5-32.
- Breiman, L. (2001b). Statistical modeling: The two cultures. *Statistical Science*. 16(3). pp.199-231.
- Butaru, F., Chen, Q., Clark, B., Das, S., Lo, A. W. and Siddique, A. (2016). Risk and Risk Management in the Credit Card Industry, *Journal of Banking and Finance*, 72, 218-239.
- Cawley, G. and Talbot, N. L. C. (2010). On Over-fitting in Model Selection and Subsequent Selection Bias in Performance Evaluation, *Journal of Machine Learning Research*, 11, 2079-2107.
- Chernozhukov, V., Chetverikov, D., Demirer, M., Duflo, E., Hansen, C. and Newey, W. (2017). Double/Debiased/Neyman Machine Learning of Treatment Effects, *American Economic Review*, 107(5), 261-265.
- Chernozhukov, V., Chetverikov, D., Demirer, M., Duflo, E., Hansen, C.,

- Newey, W. and Robins, J. (2018). Double/Debiased/Neyman Machine Learning for Treatment and Structural Parameters, *The Econometrics Journal*, 21(1), C1-C68.
- Christen, P. (2012), Data matching: concepts and techniques for record linkage, entity resolution, and duplicate detection, Springer, Berlin.
- Dell’Ariccia, G., Laeven, L. and Suarez, G. A. (2017). Bank Leverage and Monetary Policy’s Risk-Taking Channel: Evidence from the United States, *The Journal of Finance*, 72(2), 613-654.
- D’Orazio, M. Di Zio, M. and Scanu, M. (2006). *Statistical Matching: Theory and Practice*. Wiley Chichester.
- Drake, C. (1993). Effects of Misspecification of the Propensity Score on Estimators of Treatment Effect. *Biometrics*, Vol.49, pp.1231-1236.
- Fellegi, I.P. and Sunter, A.B. (1969). A theory for record linkage. *Journal of the American Statistical Association*. vol. 64, no. 328, pp. 1183–1210.
- Friedman, J.H. (2001). Greedy function approximation: A gradient boosting machine. *The Annals of statistics*. Vol.29. pp.1189-1232.
- Fu, Z., Christen, P. and Zhou, J. (2014). A Graph Matching Method for Historical Census Household Linkage. In: Tseng, V.S., Ho, T.B., Zhou, Z.H., Chen, A.L.P., Kao, H.Y. (eds). *Advances in Knowledge Discovery and Data Mining. Lecture Notes in Computer Science*. Vol. 8443. pp. 485-496. Springer, Cham.
- Gale, D. and Shapley, L.S. (1962). College admissions and the stability of marriage. *The American Mathematical Monthly*, 69(1): 9–15.
- Gilula, Z., McCulloch, R.E., and Rossi, P.E. (2006) A Direct Approach to Data Fusion, *Journal of Marketing Research*, Vol.43, pp.73-83.
- Goel, P.K. and Ramalingam, T. (2012). *The matching methodology: some statistical properties*. Springer Verlag.
- Harron, K., Goldstein, H. and Dibben, C. (2015). Methodological developments in data linkage, Wiley, Chichester.
- Heckman, J.J. (1974). Shadow Prices, Market Wages, and Labor Supply. *Econometrica*, 42(4). Pp.679-694.
- Heckman, J.J. (2000). Microdata, Heterogeneity and the Evaluation of Public Policy. *Economic Sciences*. pp.255-322.
- Herzog, T.N., Scheuren, F.J. and Winkler, W.E. (2007). *Data quality and*

*record linkage techniques*. Springer.

- Hoshino, T. (2007). Doubly Robust-Type Estimation for Covariate Adjustment in Latent Variable Modeling, *Psychometrika*, 72(4), 535-549.
- 星野崇宏. (2009). 『調査観察データの統計科学：因果推論選択バイアスデータ融合』, 岩波書店, 東京.
- Hosono, K. and Miyakawa, D. (2014). Business Cycles, Monetary Policy, and Bank Lending: Identifying the Bank Balance Sheet Channel with Firm-bank Match-level Loan Data, *RIETI Discussion Paper Series*, 14-E-026.
- Hurlin, C., Leymarie, J. and Patin, A. (2018). Loss Functions for Loss Given Default Model Comparison, *European Journal of Operational Research*, 268(1), 348-360.
- Jaro, M.A. (1989). Advances in record-linkage methodology as applied to matching the 1985 census of Tampa, Florida. *Journal of the American Statistical Association*. vol. 84. No. 406. pp. 414-420.
- Jiménez, G., Ongena, S., Peydró, J-L. and Saurina, J. (2012). Credit Supply and Monetary Policy: Identifying the Bank Balance-sheet Channel with Loan Applications, *American Economic Review*, 102(5), 2301-2326.
- Jiménez, G., Ongena, S., Peydró, J-L. and Saurina, J. (2014). Hazardous Times for Monetary Policy: What Do Twenty-three Million Bank Loans Say about the Effects of Monetary Policy on Credit Risk-taking?, *Econometrica*, 82(2), 463-505 .
- Kleinberg, J., Ludwig, J., Mullainathan, S. and Obermeyer, Z. (2015). Prediction Policy Problems, *American Economic Review*, 105(5), 491-495.
- Kuroda, H. (2021). Monetary Policy and Firms' Behavior: Transmission Channels of Monetary Policy and Japanese Firms' Structural Changes. Speech at the Meeting of Councillors of Nippon Keidanren in Tokyo.
- Lam, D.D., Nguyen, V.T., Le, M.H., Nguyen, M.T., Nguyen, Q. B., & Le, T.S. (2020). Weighted Stable Matching Algorithm as an Approximated Method for Assignment Problems. *Intelligent Information and Database Systems 2020*. pp. 174-185. Springer International Publishing.
- Malekipirbazari, M. and Aksakalli, V. (2015). Risk Assessment in Social

- Lending via Random Forests, *Expert Systems with Applications*, 42(10), 4621-4631.
- Mullainathan, S. and Spiess, J. (2017). Machine Learning: an applied econometric approach. *Journal of Economic Perspectives*, 31(2), pp.87-106.
- 森平爽一郎 (2009). 『信用リスクモデリング：測定と管理』, 朝倉書店, 東京.
- Nakashima, K., Shibamoto, M. and Takahashi, K. (2017). Risk-taking Channel of Unconventional Monetary Policies in Bank Lending, *RIEB Working Paper Series*, DP2017-24.
- On, B.-W., Koudas, N., Lee, D. and Srivastava, D. (2007). Group Linkage. *IEEE 23rd International Conference on Data Engineering*. pp. 496-505.
- Ono, A., Aoki, K. Nishioka, S., Shintani, K. and Yasui, Y. (2016). Long-term Interest Rate and Bank Loan Supply: Evidence from Firm-bank Loan-level Data, *Bank of Japan Working paper series*, 16-E-2.
- Petropoulos, A., Siakoulis, V., Stavroulakis, E. and Vlachogiannakis, N. E. (2020). Predicting Bank Insolvencies Using Machine Learning Techniques, *International Journal of Forecasting*, 36(3), 1092-1113.
- Rässler, S. (2002). *Statistical Matching*, Springer, New York.
- Rosenbaum, P. R. and Rubin, D. B. (1983). The Central Role of the Propensity Score in Observational Studies for Causal Effects, *Biometrika*, 70(1), 41-55.
- Rubin, D. B. (1974). Estimating Causal Effects of Treatments in Randomized and Nonrandomized Studies, *Journal of Educational Psychology*, 66(5), 688-701.
- Rubin, D. B. (1985). The Use of Propensity Scores in Applied Bayesian Inference. *Bayesian Statistics*. Vol.2. pp.463-472. Elsevier Science Publisher B.V.
- Rubin, D. B. (1986). Statistical matching using file concatenation with adjusted weights and multiple imputations, *Journal of Business and Economic Statistics*, 4, 87-94.
- Scharfstein, D. O., Rotnitzky, A. and Robins, J. M. (1999). Adjusting for Nonignorable Drop-out Using Semiparametric Nonresponse Models, *Journal of the American Statistical Association*, 94(448), 1096-1120.

- Sonoda, K. and Sudo, N. (2015). Is Macroprudential Policy Instrument Brunt?, *Bank of Japan Working Paper Series*, 15-E-11.
- Sonoda, K. and Sudo, N. (2023). Is Macroprudential Policy Instrument Brunt? Empirical Analysis Based on Japan's Experience from 1970s to the 1990s, *Journal of Money, Credit and Banking*, (in press).
- Stuart, E. A. (2010). Matching methods for causal inference: A review and a look forward, *Statistical science*, 25, 1-21.
- Suss, J. and Treitel, H. (2019). Predicting Bank Distress in the UK with Machine Learning, *Bank of England Staff Working Paper*, No. 831.
- Takabe, I., and Yamashita, S. (2020). New Statistical Matching Methods Using Multinomial Logistic Regression Model. *Advanced Researches in Classification and Data Science*. Pp.265-274.
- 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, 東京.
- 美添泰人. (2005). 統計的照合手法の基礎理論と最近の適用例, *青山経済論集*, 56, pp.43-71.
- Zhou, J., Li, W., Wang, J., Ding, S. and Xia, C. (2019). Default Prediction in P2P Lending from High-dimensional Data Based on Machine Learning. *Physica A*. 534.

## 謝辞

博士論文の作成に当たり、主任指導教員となっていたいただいた統計数理研究所の山下智志教授には、統計数理研究所の副所長及びリスク解析戦略研究センターのセンター長という御多忙な立場の中、長期に渡り御指導をお引き受けいただき、深く感謝申し上げます。この研究は、社会人学生として、普段の業務と並行して行ってきたものですが、このことに加えて、私的な事情による休学期間をはさんで長い期間がかかりました。この間、研究の進捗を辛抱強くお待ちいただいたことに厚くお礼を申し上げます。山下教授からは、統計科学に関する基礎的な事項から応用的な内容まで、研究に必要な様々な点を御指導いただくとともに、各種のデータコンソーシアムや、実務的な観点からの問題解決にも携わられたご経験から、実際に収集されたデータを用いた分析の難しさを踏まえたうえで具体的な解決法もご指導いただき、また、実データ分析の意義についての励ましもいただきました。これらの内容は、研究の遂行のみならず、実データの分析を業務として行う上でも、大変参考になりました。重ねて御礼申し上げます。

副主任指導教員及び本博士論文の学位審査における主査となっていたいただいた統計数理研究所の川崎能典教授からは、論文の審査や学業進捗報告の機会を通じて、論文を改善するための様々な御助言をいただいたこと、また、お忙しい中で博士論文審査の主査をお引き受けいただきましたことに、深くお礼を申し上げます。

本論文の審査の過程において、数々の御助言をいただきました、筑波大学の野忠士教授、同志社大学の津田博史教授、統計数理研究所の南和宏教授にも、御多忙の中、お時間を割いていただき、深くお礼を申し上げます。様々な観点からの重要なコメント・御指摘により、博士論文の内容を大幅に改善することができました。

統計数理研究所の藤澤洋徳教授には、本研究の初期段階において、実データの変数選択に正則化を適用するにあたってのアドバイスを頂きました。また、専攻長として公的マイクロデータの利用申請に際してご助力頂いたことにも、深くお礼を申し上げます。

立正大学の髙部勲教授には、本研究の先行研究にあたる研究を行われたことから、研究内容について様々なご助言を頂くと共に、総務省で公的マイクロデータの利活用にご経験から、公的マイクロデータの利用申請の手続きについてもご助言を頂きました。また、山下先生研



研究室の先輩として、学位申請までの様々な手続きについてもご助言を頂きました。重ねて感謝を申し上げます。同じく山下先生研究室の先輩として、入学当初様々にご助力頂いた東京海洋大学の田上悠太准教授にも感謝を申し上げます。

最後に、情報・システム研究機構立川共通事務部の担当職員の皆様、統計数理研究所・リスク解析戦略研究センター等の職員の皆様及び山下先生研究室の秘書の大福直子様には、入学から博士審査に至るまでの様々な手続き等に関して、非常に多くの面でサポートをしていただきました。ここに深くお礼を申し上げます。