## 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

園田 桂子1・山下 智志2

(受付 2020 年 7 月 3 日;改訂 2021 年 6 月 18 日;採択 6 月 22 日)

## 要 旨

金融政策効果の実証分析は専ら経済分野で扱われ、主にパネル回帰分析が行われてきた。し かし、これらは評価と解釈がしにくい高次元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。本稿では、機械学習 の予測精度の高さを利用して、金融政策の効果について考察する、1 つめの分析では、企業の 借入前年比を被説明変数に、金融政策変数を離散変数として説明変数に用い、かつ、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と考えた上で,Double Machine Learning(DML)を用いて,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. 2 つめの分析では、企業の借入前年比を増加か否かで離散変数に変換して被説明変数に、 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 数に用いてランダムフォレストによる予測モデルを構築し,Partial Dependence Plot(PDP), Accumulated Local Effect (ALE), 及び2次元 ALE による金融政策への感応度分析を行った. この結果、1 つめの分析と同様に、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 活発に行う交互作用が認められることが示唆された.

キーワード:データ結合, 金融政策効果, 平均処置効果, Double Machine Learning (DML), Partial Dependence Plot (PDP), Accumulated Local Effects (ALE).

## 1. 導入

金融分野では、ミクロデータに機械学習と呼ばれる手法を適用する試みが進んでいる。例えば、Peer to Peer Lending (P2P) 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

<sup>1</sup> 総合研究大学院大学 複合科学研究科統計科学専攻: 〒190-8562 東京都立川市緑町 10-3

<sup>2</sup> 統計数理研究所:〒 190-8562 東京都立川市緑町 10-3

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; Bäruning et al., 2019)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、機械学習に基づくモデルの方が高い予測精度を達成している。

政策効果に関心を持つ計量経済の分野においては、ミクロデータを用いた政策効果の検証にはパネル回帰分析による検証が多く行われてきた。しかし、回帰モデルを用いた方法は、被説明変数と説明変数の関係を正しくモデル化しなければ、推計結果がバイアスを持つ。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行うことがあるが(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。そこで、モデルの誤設定を避けながら大量データを扱うことができて予測精度が高い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)。

機械学習を用いて金融政策の効果を検証する方法としては、観測データに関する統計的因果推論(星野,2009)の枠組みに機械学習を取り入れる方法が考えられる。ただし、この枠組みは、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が前提となる。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介入は、発動している時と、景気に中立的で発動していない時をデータ上区別することが難しい。別途の方法として、機械学習の手法で構築したモデルにおいて、金融政策に対する被説明変数の反応を見る方法が考えられる。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)、この方法は、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、多くの変数を用いながら交互作用も表現できるほか、オーバーフィッティングをコントロールしながら、高い精度で金融政策の効果を予測することができる。また、これらの利点を前提にした交互作用の効果を見ると、どのような銀行や企業が、金融政策に対してどう反応するかを観察できることから、金融政策の伝播経路に関する既存の理論を実証するのにも有益である。

ミクロデータに基づく金融政策の効果の実証分析に機械学習を用いた先行研究は、調査した限りみつからない、パネル回帰分析による先行研究は、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、被説明変数のデータ数が 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。

本稿では、機械学習の予測精度の高さを利用して、金融政策の効果、特にその波及経路を重要とみなして検証する。本稿の構成は以下の通りである。2節では、企業-銀行間の取引関係データを軸として、企業財務データ、銀行財務データ、マクロ経済データ、金融政策データを結合する方法を説明する。3節では、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と仮定して、企業の借入

前年比を被説明変数とし、金融政策変数を離散変数として説明変数に用いて、金融政策の波及 経路を推定する。4節では、金融政策の介入は、企業の借入がいくら増えるかというよりは、 借入を増やすか否かという貸し手と借り手の離散的意思決定に影響すると仮定して、企業の借 入前年比を増加か否かで離散変数にしてモデルの被説明変数とし、金融政策変数を連続変数の まま説明変数に用いた上で、機械学習による予測モデルを構築する。4節では、モデルを推定 した後に、金融政策の介入に対する感応度分析によって、金融政策の効果と波及経路を推定す る。各分析の考察は各節の最後で行い、5節で、全体のまとめと今後の課題を述べる。

## 2. 分析データと企業財務、銀行財務、マクロ経済データ、金融政策データの結合

分析データは、先行研究と同様に、①企業と銀行間の取引関係データ、②銀行の財務データ、③企業の財務データ、④マクロ経済データ、⑤金融政策データを、企業の固有 ID、銀行の固有 ID、年度を使って、完全照合によって結合させて作成する(図 1). 元となる 5 つのデータベースのうち、3 つは 3 次元配列で、2 つは行列である.

まず、全ての  $y_{c,b,t}$  に、番号  $i(1,\ldots,n|n=n_c\times n_b\times n_t)$  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 y にする。y の中身は下記のような並びになっている。

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

 $(2.2) \quad \boldsymbol{y} = \operatorname{vec}(\boldsymbol{Y}_{c,b,t})$ 

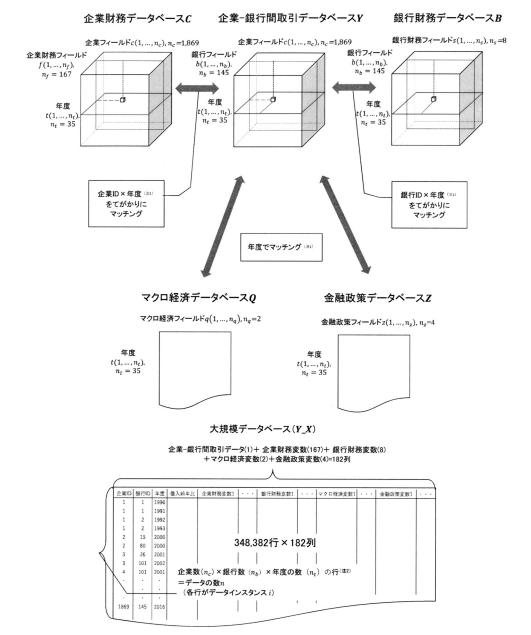
$$= \begin{bmatrix} \{(y_{1,1,1}, \dots, y_{1,n_b,1}), (y_{1,1,2}, \dots, y_{1,n_b,2}), \dots, (y_{1,1,n_t}, \dots, y_{1,n_b,n_t})\}, \\ \{(y_{2,1,1}, \dots, y_{2,n_b,1}), (y_{2,1,2}, \dots, y_{2,n_b,2}), \dots, (y_{2,1,n_t}, \dots, y_{2,n_b,n_t})\}, \\ \vdots \\ \{(y_{n_c,1,1}, \dots, y_{n_c,n_b,1}), (y_{n_c,1,2}, \dots, y_{n_c,n_b,2}), \dots, (y_{n_c,1,n_t}, \dots, y_{n_c,n_b,n_t})\} \end{bmatrix}^T$$

次に、3 次元配列である C, B について、2 次元配列にする。企業財務データベース 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) 
$$\mathbf{x_f} = \operatorname{vec}(x_f)$$

$$= \left[ (x_{1,f,1}, \dots, x_{1,f,n_t}), (x_{2,f,1}, \dots, x_{2,f,n_t}), \dots, (x_{n_c,f,1}, \dots, x_{n_c,f,n_t}) \right]^T$$

こうして作成した $x_f$ 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、



(注)1. 企業-銀行間取引データベースのt年度に対して、それ以外のデータベースのt-1年度をマッチングさせている.

- 2. 欠損値が発生している行は削除している.
- 3. データ行nは、分析の際、ブートストラップによってランダムにサンプリングされる。

図 1. データの結合方法.

 $n_b$  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.

銀行財務データベース 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) 
$$x_s = \text{vec}(x_s)$$
  
=  $[(x_{1,s,1}, \dots, x_{1,s,n_t}), (x_{2,s,1}, \dots, x_{2,s,n_t}), \dots, (x_{n_b,s,1}, \dots, x_{n_b,s,n_t})]^T$ 

こうして作成した  $x_s$  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.

マクロ経済データベース 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。金融政策データベース 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  $Y_X$  である (図 1). このうち、y を除いたものを説明変数行列 X と呼ぶことにする.

 $Y_{-}X$  は、例えば y において、ある銀行とある企業の間に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く、そのまま使用すると分析結果にバイアスが生じる。本研究は欠損値が持つ情報には関心がなく、欠損値の存在が分析上のデメリットになることから、 $Y_{-}X$  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、 $Y_{-}X$  は、348,382 件(行)×181 変数(列)から成るデータとなった(変数リストは表 1)。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の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 C から除外している。また、相対的に欠損値が少ない銀行の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 B から除外している。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4つのデータベースは被説明変数の1年度前の値を要素とした。

銀行と企業間の取引関係データの元となるのは、日経 NEEDS 社が有償で提供している「金融機関別借入金データ」で(Nakashima et al., 2017; Hosono and Miyakawa, 2014 と同じ)、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。企業と銀行の財務データは、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。データを結合した後、下記のようなデータ加工を行った。

外れ値への対応:財務指標については、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。コールレートや日銀当座預金(金融政策変数)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。このため、対数変換によって、相対的に低い水準を強調する目的がある。また、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。この傾向への対処の目的もある。

また、分析において、借入前年比を離散的行動データとして扱う場合は、 $y_{c,b,t}$  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  $\delta^y$  を作成して用いている。

(2.5) 
$$\delta^{y} = \begin{cases} 0 & (y_{c,b,t} \le 0) \\ 1 & (y_{c,b,t} > 0) \end{cases}$$

## 表 1. 変数一覧.

マクロ経済環境	(26)商品·製品回転日数
(1) 実質GDP成長率	(27) 半製品・仕掛品回転日数
(2) 実質GDP成長率前年度差	(28) 原材料・その他回転日数
	(29) 売上高原価率
金 融 政 策	(30) 売上高販管費率
(1) コールレート	(31) 売上高減価償却費率(B)
(2) コールレート前年度差	(32) 売上高純金利負担率
(3) 日銀当座預金	(33) 売上高支払利息割引料率
(4) 日銀当座預金前年度差	(34) 売上高設備投資比率(B)
(4) 自致自注原证的干及在	(35) 償却前内部留保率
和 仁 の H 政 比 博	(36)投融資利回り
銀行の財務指標	
(1) 預貸率	(37) 純資産回転率
(2) 預証率	(38) 純利益率
(3) LN(総資産)	(39)長期負債対自己資本比率
(4) 経常利益/総資産	(40) 自己資本営業利益率
(5) 国債/総資産	(41) 自己資本利払後事業利益率
(6) 地方債/総資産	(42) 自己資本経常利益率
(7) 结咨定 / 经咨定	(43) 売上高原価率
(8) 上层体上的生产,只是2014年)(2015年)(8)	
(8) 十国債+地方債一日銀預け金) /総資産	(44) 売上高販管費率
Libert Possible Assessment Hoseland	(45) 売上高減価償却費率(B)
企業の財務指標	(46) 売上高純金利負担率
ー 株 当 た り 指 標	(47) 売上高支払利息割引料率
(1) 1株当たり売上高	(48) 売上高設備投資比率(B)
(2) 1株当たり事業利益	(49) 償却前内部留保率
(3) 1株当利払後事業利益	(50) 純利益率
(4) 1株当たり営業利益	(51)長期負債対自己資本比率
(5) 1株当たり経常利益	資本利益率指標
(6) 1株当たり税引前利益	(52) 使用総資本総利益率
(7) 1株当たり利益	(53) 使用総資本事業利益率
(8) 1株当たりEBIT	(54) 使用総資本事業利益率一利払後
	(55)使用総資本営業利益率
(9) 1株当たりEBITDA(B)	
(10) 1株当たり簡易版キャッシュフロー(B)	(56) 使用総資本経常利益率
(11) 1株当たり純資産(A)	(57) 使用総資本税引前利益率
(12) 1株当たり純資産(B)	(58) 使用総資本利益率
そ の 他 指 標	] (59) 投資収益率-ROI
(13) 資本市場調達・借入比率	(60) 投下資本収益率-ROIC
(14) 海外売上高比率(3ヵ月)	マージン 関連
収 益 性	(61) 売上高総利益率
(15) 企業利潤率	(62) 売上高事業利益率
(16) 自己資本営業利益率	(63) 売上高事業利益率一利払後
(17) 自己資本司払後事業利益率	(64) 売上高営業利益率
(18) 自己資本経常利益率	(65) 売上高経常利益率
(19) 固定資産回転率	(66) 売上高EBIT比率
(20) 有形固定資産回転率	(67) 売上高EBITDA(B)比率
(21) 有形固定資産回転率一取得価格基準	(68) 売上高総利益率
(22)流動資産回転日数	(69) 売上高事業利益率
(23) 売上債権回転日数	(70) 売上高事業利益率ー利払後
(24) 買入債務回転日数	(71) 売上高営業利益率
(25) 棚卸資産回転日数	(72) 売上高経常利益率
(20) 则即具压口私口奴	(72) 光工高柱市刊並平 (73) 売上高EBIT比率
	I (74) 売上高EBITDA(B)比率

## 3. 借入前年比を連続変量として扱った場合の金融政策効果と波及メカニズムの検証

## 3.1 モデルの概要と分析に用いる変数

本分析では、以下の方法で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データグループ(処置群)の被説明変数の値を $y^1$ 、介入を受けなかったデータグループ(対照群)の被説明変数の値を $y^0$ とする。実際に介入を受けたデータ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データグループがもし介入を受けた場合も反実仮想し、全てのデータについて、2つの潜在的な被説明

## 表 1. (つづき)

安 全 性	(119) 固定長期適合率
(75) 手元流動性比率	(120) 自己資本比率(A)
(76) 支払準備率	(121) 自己資本比率(B)
(77) 預借率	(122) 負債比率
(78) 現金•預金対有利子負債比率	(123) 有利子負債額
(79) 当座比率	(124) 純有利子負債額
(80) 流動比率	(125) 有利子負債対自己資本比率
(81) 正味運転資本額	(126) 純有利子負債対自己資本比率
(82) 純運転資本額	(127) 借入金依存度
(83) 正味運転資本組	(128) 有利子負債利子率
(84) 売上債権対買入債務比率	(129) インタレスト・カバレッジ(A)
(85) 棚卸資産対買入債務比率	(130) インタレスト・カバレッジ(B)
(86) 受取手形割引高回転日数	(131) 減価償却率
(87) 固定負債対有形固定資産比率(A)	(132) 有形固定資産減価償却累計率
(88) 固定負債対有形固定資産比率(B)	(133) 増収率(前年同期比)
(89) 固定比率	(134) 自己資本成長率(前年同期比)
(90) 固定長期適合率	キャッシュフロー関連
(91) 自己資本比率(A)	(135) 簡易版キャッシュフロー(B)
(92) 自己資本比率(B)	(136) EBIT
(93) 負債比率	(137) EBITDA(B)
(94) 有利子負債額	(138) 経常収支
(95) 純有利子負債額	(139) 経常収支比率
(96) 有利子負債対自己資本比率	(140) 簡易版キャッシュフロー(A)
(97) 純有利子負債対自己資本比率	(141) 株主向けキャッシュフロー
(98) 借入金依存度	(142) EBITDA(A)
(99) 自己金融比率	(143) EBITDA(B)
(100) 有利子負債利子率	(144) 経常収支
(101) インタレスト・カバレッジ(A)	(145) キャッシュフロー対負債比率
(102) インタレスト・カバレッジ(B)	(146) キャッシュフロー対固定負債比率
(103) 減価償却率	(147) キャッシュフロー対流動負債比率
(104) 有形固定資産減価償却累計率	(148) キャッシュフロー対長期負債残高比率
(105) 手元流動性比率	(149) キャッシュフロー対有利子負債比率
(106) 支払準備率	(150) インタレストカバレジ・キャッシュフロー
(107) 預借率	(151) キャッシュフロー対設備投資比率(B)
(108) 現金・預金対有利子負債比率	(152) キャッシュフロー対売上高比率
(109) 当座比率	(153) キャッシュフロー対負債比率
(110) 流動比率	(154) キャッシュフロー対固定負債比率
(111) 正味運転資本額	(155) キャッシュフロー対流動負債比率
(112) 純運転資本額	(156) キャッシュフロー対長期負債残高比率
(113) 正味運転資本比率	(157) キャッシュフロー対有利子負債比率
(114) 売上債権対買入債務比率	(158) インタレストカバレジ・キャッシュフロー
(115) 棚卸資産対買入債務比率	(159) キャッシュフロー対売上高比率
(116) 固定負債対有形固定資産比率(A)	ROE関連指標
(117) 固定負債対有形固定資産比率(B)	(160) ROE(自己資本利益率)(A)
(118) 固定比率	(161) 売上高利益率
	(162) 売上高税引利払前利益率
	(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)(B)
	(166) 税金等負担効果(1一税率)
	(167) 使用総資本回転率
	1 com becoming to the TM 1

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).

想定しているのは、被説明変数が、金融政策変数とそれに係るパラメータとしての平均措置効果と、金融政策以外の説明変数とそれに係るパラメータ、そして、観察されない被説明変数の決定因子(期待値は0)から成るというモデルである。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。また、説明変数を本節では共変量と呼ぶ。なお、本節で検証する金融政策変数は、 $x_z$ と異なり、新たに作成する変数である。被説明

		$oldsymbol{Z}^p$				
年度	年別データ数	1列目(	(Tight)	2列目(l	_oose)	期間データ数
1982	5,463		0		1	
1983	15,629		0		1	
1984	5,296	中立	0	緩和	1	36,086
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	46.620
1989	10,911	しいかない	. 1	中立	0	46,630
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	12,746
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	16,572
2007	8,310	くり作作して	1	十五	0	10,372
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	

表 2. 因果効果の推定で使用する金融政策変数.

変数ベクトルは既出のyで、共変量はXから選択した一部の変数である.

金融政策変数は、金融政策による介入があったデータとなかったとみなせるデータの区別が難しい。しかし、緩和的政策が採られていた時期と引き締め的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)。そこで、緩和的な政策と引き締め的な政策の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 $\mathbf{Z}^p$ を作成した(表2)。この行列が $n_c \times n_b$ 個存在しており、n行2列の行列となる。

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は伝統的金融政策に加えて非伝統的金融政策までと幅広い政策手段が採られている。各年毎のデータ数を見ると、どの年度のデータ数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(Tight 変数)では処置群が 22%(対照群が 78%)、 $Z^p$ の2列目(Loose 変数)では逆に処置群が 78%(対照群が 22%)と偏りがある。

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2のようなものである.次

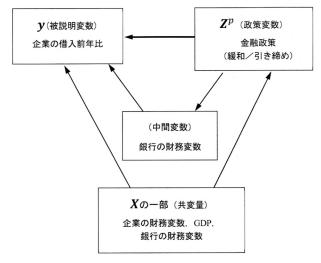


図 2. 因果効果の推定で想定する変量間の影響関係.

項で述べる推計方法を採ると、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、金融政策変数が被説明変数に与える影響をみることができる.

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(共変量である)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。

## 3.2 モデルのパラメータ推定方法

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,実際には処置群は  $y^0$  が,対照群は  $y^1$  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,傾向スコア(Rosenbaum and Rubin, 1983)を用いて,推定の偏りの調整を行う(理論については星野, 2009 を参照).

傾向スコアの推定は、共変量を説明変数とした、金融政策変数の2値分類予測で行う.本研究は多数の共変量候補を持つことと、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趣旨で、ランダムフォレストモデル (Breiman, 2001)による2値分類の確率推計を行った。

なお、計算の効率化のため、共変量として使用する企業の財務データは、全 167 変数から 35 変数を選択した。選択にあたっては、 $\delta^y$  を被説明変数とした単変数ロジスティック回帰を 行って、AUC が相対的に高いグループ (AUC が 0.52 以上)に属した変数を選択した。銀行の 財務データ(全8 変数)に関しては、全てを用いている。平均処置効果の推計の際しては、二重 にロバストな推計 (Bang and Robins, 2005; Hoshino, 2007)を行う。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

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

表 3. 因果効果の推定結果(平均処置効果).

ノードの不純度の指標にジニ係数を用いた上で、モデル1と2については木の数6,木の深さ10 モデル3と4については木の数3.木の深さ3に設定して推計した。

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)。

#### 3.3 モデルの推定結果と考察

平均措置効果を推計した結果が表 3 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.

傾向スコアの推計に用いたランダムフォレストモデルによる 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.

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%)、引き締め的な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%)、引き締め的な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。

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。

# 4. 借入前年比を離散的行動データとして扱った場合の金融政策効果と波及メカニズムの検証

3節では、企業の借入前年比を連続変数のまま被説明変数とした.しかし、金融政策は、企業や銀行がどれだけ借入(貸出)を増やすかというよりは、元々、借入(貸出)前年比が変化しないケースが多い中で、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仮定して、本節では、企業の借入前年比を離散変量に変換して被説明変数としたうえで分析する.

## 4.1 分析方法

## 4.1.1 モデルの概要と分析に用いる変数及び推定方法

本節では,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モデルを構築する。被説明変数には, $\delta^y$  を,説明変数には,X を用いる。すなわち,前節と異なり,金融政策変数に $x_z$  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。近年,金融政策手段が多様化しているが,何れの手段も日銀当座預金の増減に反映されるためである。パネル回帰モデルによる先行研究とは異なり,決定木ベースのモデルでは,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) しか選べず,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ため,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は何れも決定木に基づいており,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されるため,交互作用項も取り込まない。i 番目の被説明変数を  $\delta^y_i$ ,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。

$$f(x) = P_r(\delta_i^y = 1|x_i)$$

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.

(4.2) 
$$f(x) = \arg\min_{a} E[\{\delta_i^y - g(x_i)\}^2]$$

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  $\hat{f}(x)$  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 $^{1}$ 、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 $^{2}$ ).

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 Cawley and Talbot, 2010)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

表 4. 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

criterion	ノードの不純度の指標	gini <u>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>

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。表 4 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ランダムにサンプリングされている。

モデルの精度比較に用いた各種指標の定義については以下の通り.

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.

金融政策の効果の観点からは、正確度と適合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良くなくとも、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、偽陽性率や偽陰性率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、分析対象としている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)、陰性適中率は高いと想定される。

### 4.1.2 感応度分析の方法

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  $x_z$  やマクロ経済変数  $x_q$ ,以下では  $x_z$  を例とする)が他の変数と相関していない事を仮定して, $x_z$  の値のみが変化した時,被説明変数ベクトル 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  $x_z$  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。本稿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

表 5. 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

	正確度	陽性 的中率	陰性 適中率	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

	5-fold 平均	5−fold 標準偏差			分布を仮定 頼区間
RF	0.79	0.0016	[ 0.79	6,	0.801 ]
GB	0.80	0.0018	[ 0.79	9,	0.805 ]

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、 $x_z$  は他の変数(例えば銀行の財務変数ベクトル $x_s$ )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、 $x_z$  と $x_s$  の条件付分布  $p(x_z|x_s)$  を考え、かつ、予測の変化の平均を計算することで、 $x_z$  および $x_s$  単独の効果と、 $x_z$  と $x_s$  の交互作用をそれぞれ別に表す 2 次元の Accumulated Local Effects (以下、ALE)プロットによる感応度分析も行った (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。感応度分析のアルゴリズムには R. の ALEPlot を使用した。

#### 4.2 推定結果

## 4.2.1 モデルの推定結果

表 5 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表である。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章している。正確度はランダム フォレストが 0.76、勾配ブースティングは 0.77、適合度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、想定の通 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.

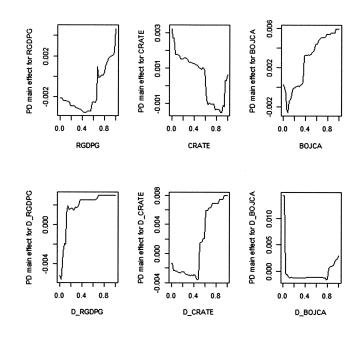
## 4.2.2 感応度分析の結果

## 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3は、構築したランダムフォレストモデルに基づいて、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。

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指標は一つもない。実質 GDP のグラフを見ると、過去の実質 GDP  $(-3.4\sim6.2)$  を  $0\sim1$  の範囲に変換すると、概ね 0.5



横軸(カッコ内は観測最小値~最大値,単位)

· RGDPG: 実質GDP成長率(-3.4~6.2, %)

・ CRATE: コールレート(0.00~7.77, %)

· BOJCA: 日銀当座預金残高(21,771~1,601,772億円)

· D RGDPG: 実質GDP成長率前年度差(-4.6~5.5, %)

· D CRATE: コールレート前年度差(-2.77~2.02, %)

D\_BOJCA: 日銀当座預金残高前年度差(-212,845~681,439億円)

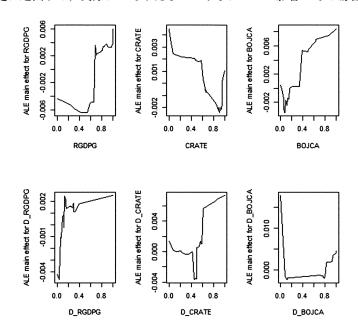
図 3. マクロ経済変数と金融政策変数に対する Partial Dependence Plot (PD プロット).

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 $(0.00\sim10.90)$ を $0\sim1$ の範囲に変換すると、 $0.6\sim0.9$ 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 $(21,771\sim920,333$  億円)を $0\sim1$  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  $(-4.6\sim5.5)$  を  $0\sim1$  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  $(-3.81\sim2.02)$  を  $0\sim1$  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  $(-212,845\sim681,439$  億円) を  $0\sim1$  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4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



横軸(カッコ内は観測最小値~最大値,単位)

· RGDPG: 実質GDP成長率(-3.4~6.2, %)

・ CRATE: コールレート(0.00~7.77, %)

· BOJCA: 日銀当座預金残高(21,771~1,601,772億円)

D RGDPG: 実質GDP成長率前年度差(-4.6~5.5, %)

· D CRATE: コールレート前年度差(-2.77~2.02, %)

· D BOJCA: 日銀当座預金残高前年度差(-212,845~681,439億円)

図 4. マクロ経済変数と金融政策変数に対する Accumulated Local Effect (ALE): Main Effect.

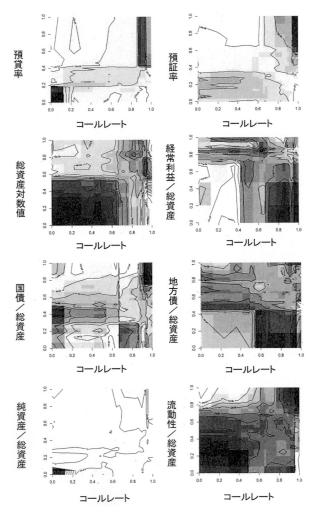


図 5. 金融政策変数に対する Accumulated Local Effect (ALE): Second-order.

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 5 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 当座預金残高)と8つの銀行の財務指標変数(預貸率、預証率、総資産対数値、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。

16 のグラフを見渡すと、どの変数の組み合わせ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大きくなく、最大でも 0.25% (コールレートと銀行の純資産/総資産の組み合わせ)である。

過去のコールレートの値を  $0\sim1$  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

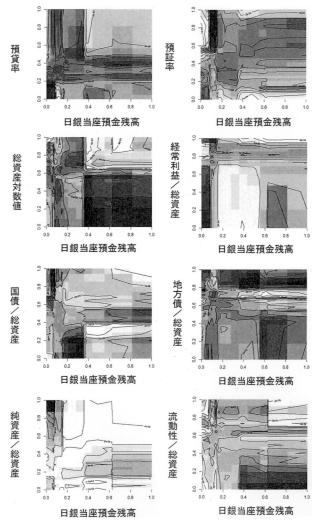


図 5. (つづき)

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.

## 4.3 感応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)で企業の借り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を彷彿とさせる。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姿を彷彿とさせる。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。

## 5. 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2つの分析を行った。2つの分析によって、企業の借入前年比への影響は、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と、金融政策の影響度合いは大きくないことが、矛盾なく導き出された。また、2つ目の分析の結果、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あること、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あ

ることもわかった.

今後の課題は以下の通りである。本分析では金融政策を離散変数と連続変数の両パターンで取り扱かったが、離散変数への情報の集約に精緻化の余地がある。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、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工夫の余地がある。また、一つ目の分析で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と考えられる。更に、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結合を用いて多種のデータベースを結合すれば、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。

## 注.

- 1) 本アルゴリズムは、ランダムフォレストモデルを提案した Breiman (2001)に基づいているとされているが、データがどのクラスに属するかの予測は、各決定木がいずれか一つのクラスに Voting(投票)して多数決で決めるのではなく、各決定木の確率的予測を平均した結果で決める扱いとしている。
- 2) 本アルゴリズムは、他の勾配ブースティングアルゴリズム(例えば XgBoost)が訓練の際に決定木の層を成長させてゆくのに対して(Level-wise)、決定木の葉を成長させてゆく(Leaf-wise). LightGBM は過学習を招きやすい傾向もあるが、Leaf-wise を採用していることと、変数の選択にあたってヒストグラム構造を採用したことで計算が高速化されている。なお、ランダムフォレストと勾配ブースティングはいずれも決定木ベースの手法であり、決定木ベースではないサポート・ベクター・マシン(SVM)といった手法による結果と照らし合わせるのが望ましいが、同手法は計算コストが高く、本分析のようにデータ数が多いケースでは、結果を得ることができなかった。

### 謝辞

改稿にあたり、有益なコメントをいただいた2名の査読者と編集委員に感謝申し上げます。

## 参考文献

- Alessi, L. and Detken, C. (2018). Identifying excessive credit growth and leverage, *Journal of Financial Stability*, **35**, 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), 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), 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.
- Bräuning, M., Malikkidou, D., Scalone, S. and Scricco. G. (2019). A new approach to early warning systems for small european banks, European Central Bank Working Paper Series, No. 2348, European Central Bank, Frankfurt am Main.
- Breiman, L. (2001). Random forest, Machine Learning, 45, 5-32.
- 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.
- 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.
- 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, Research Institute of Economy, Trade and Industry, Tokyo.
- 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.
- 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.
- Malekipirbazari, M. and Aksakalli, V. (2015). Risk assessment in social lending via random forests, Expert Systems with Applications, 42(10), 4621–4631.
- 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, Research Institute for Economics and Business Administration, Kobe University, Kobe.
- 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, Bank of Japan, Tokyo.

- 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.
- 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.
- 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, Bank of Japan, Tokyo.
- Suss, J. and Treitel, H. (2019). Predicting bank distress in the UK with Machine Learning, Bank of England Staff Working Paper, No. 831, Bank of England, London.
- 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.
- 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**.

## Data Linkage and Machine Learning Approach for Identifying Monetary Policy Effects and Transmission Mechanisms

Katsurako Sonoda¹ and Satoshi Yamashita²

 $^1\mathrm{Department}$  of Statistical Science, School of Multidisciplinary Sciences, The Graduate University for Advanced Studies, SOKENDAI  $^2\mathrm{The}$  Institute of Statistical Mathematics

In many empirical analyses of the effects of monetary policy, panel regression analyses are conducted that introduce many dummy variables that cannot be evaluated or interpreted. In such settings, dummy variables can have negative effect to estimation of other variables' true parameters in the regression equation. In this paper, we combined multiple database by data linkage, and then studied the effect of monetary policy, taking advantage of the high prediction accuracy of machine learning. We conducted two analyses. In both analysis, corporate borrowing was used as the dependent variable, and the monetary policy variable was used as the explanatory variable along with other variables. In the first analysis, we estimated the average treatment effect (ATE) of monetary easing or tightening policy using the Double Machine Learning (DML) algorithm in the framework of Rubin's causal effect. In this analysis, the dependent variable is continuous, whereas the monetary policy variable is a discrete variable. We consider that the financial variables of banks and firms and macroeconomic environment variables affect the dependent variable and also influence intervention or non-intervention in monetary policy. Our results suggested that monetary policy intervention exerts an effect through firms' balance sheets, but that the size of the effect is small. In the second analysis, we constructed a random forest forecasting model. In this analysis, the dependent variable was discrete and the monetary policy variable was continuous, as monetary policy is expected to affect the decision of whether to increase borrowing, but not the extent of the change in borrowing. Then, we analyzed the sensitivity to monetary policy using the Partial Dependence Plot (PDP), Accumulated Local Effect (ALE), and two-dimensional ALE. The results confirmed that the impact of monetary policy is small, and that monetary policy has a greater impact on the demand for funds by firms than on the supply of funds by banks; however, the impact of monetary policy may be due to a change in policy direction rather than the degree of tightening or easing and the extent of the change. We also detected an interaction effect in which smaller banks and banks with lower liquidity holdings are more active in lending to firms under accommodative monetary policy.