



日本銀行ワーキングペーパーシリーズ

## 企業のインフレ予想形成に関する新事実：Part II —機械学習アプローチ—

調査統計局経済調査課  
経済分析グループ

No.17-J-4  
2017年5月

日本銀行  
〒103-8660 日本郵便（株）日本橋郵便局私書箱 30号

日本銀行ワーキングペーパーシリーズは、日本銀行員および外部研究者の研究成果をとりまとめたもので、内外の研究機関、研究者等の有識者から幅広くコメントを頂戴することを意図しています。ただし、論文の中で示された内容や意見は、日本銀行の公式見解を示すものではありません。

なお、ワーキングペーパーシリーズに対するご意見・ご質問や、掲載ファイルに関するお問い合わせは、執筆者までお寄せ下さい。

商用目的で転載・複製を行う場合は、予め日本銀行情報サービス局 (post.prd8@boj.or.jp) までご相談下さい。転載・複製を行う場合は、出所を明記して下さい。

# 企業のインフレ予想形成に関する新事実：PART II

## —機械学習アプローチ—\*

日本銀行調査統計局 経済調査課 経済分析グループ<sup>†</sup>

平成 29 年 5 月 16 日

### 概要

本稿は、企業のインフレ予想がどのように形成されるのかを探るため、大規模データを用いて、企業のインフレ予想形成行動を「機械」に学習させることを試みる。学習に用いるデータは、宇野・永沼・原 [1] と同じ「短観」の個票データである。「機械」による主たる学習の結果は、次の四点である。第一に、「物価全般」予想は、各企業に共通したマクロ変数と密接に関連している。第二に、「物価全般」「自社の販売価格」いずれでみても、GDP ギャップに関連するような実物変数が予想形成に果たす役割の重要度は低い。第三に、「物価全般」と「自社の販売価格」とでは、予想形成メカニズムが異なっている。第四に、長期のインフレ予想は、各企業に固有のミクロ変数の影響を受けにくい。

JEL コード： C55、E31、E52、E58

キーワード： インフレ予想、ランダム・フォレスト、ベイジアン・ネットワーク、金融政策

---

\*本稿の作成にあたっては、久野遼平氏 (東京大学) に多大なるご助力を頂いている。久野先生には、機械学習の基本的な文献の紹介、学習手法の選択、R のコーディングに至るまで丁寧にご指導を頂いている。また、青木浩介氏 (東京大学)、桑原茂裕氏 (以下、日本銀行)、関根敏隆氏、中村康治氏、一上響氏、伊藤智氏、稲村晃希氏から有益なコメントを頂いた。ここに記して感謝したい。ただし、ありうべき誤りはすべて筆者たちの責任である。また、本稿に示されている意見は、日本銀行の公式見解を示すものではない。

<sup>†</sup>連絡先： [yousuke.uno@boj.or.jp](mailto:yousuke.uno@boj.or.jp)

## 1 はじめに

企業は、どのようにインフレ予想を形成するだろうか。この問いに対する、もっとも素直なアプローチは、経済理論にもとづいて企業の予想形成行動をモデル化し、実際のデータを用いてそのモデルのもっともらしさを検証することであると考えられる。実際、インフレ予想形成に関しては、これまで、多くの理論モデルが提示され、そうしたモデルを実際のデータで検証することも多くなされてきた。たとえば、Coibion *et al.* [12] と Kumar *et al.* [16] は、ニュージーランド企業を対象にインフレ予想に関する大規模なサーベイを行い、その個票データを用いて、Mankiw and Reis [18] らの粘着情報モデルや Sims [23] らのノイズ情報モデルにもとづいた実証分析を行っている。また最近では、宇野・永沼・原 [1] が、シンプルな粘着情報モデルにもとづいて、企業のインフレ予想形成の特徴点や金融政策に対する含意について議論している。

本稿は、こうしたこれまでの取り組みとはまったく異なる方向から、企業のインフレ予想形成メカニズムにアプローチする。本稿は、企業のインフレ予想に関する大規模なデータを用いて、企業の予想形成行動を「機械」に学習させることを試みる。すなわち、これまでの多くの先行研究のように、最初に企業の予想形成行動をモデル化するのではなく、先験的な制約をできる限り設けずに、「機械」が学習した結果を通じて、企業のインフレ予想形成行動を理解することを狙う。学習に用いるデータは、宇野・永沼・原 [1] と同じ、日本銀行調査統計局が四半期ごとに作成・公表する「全国企業短期経済観測調査(以下、短観)」の個票データである。Varian [26] が指摘するように、機械学習の手法を経済学の実証研究に応用しようとする取り組みは、近年、徐々に活発になってきている。もっとも、インフレ予想に関しては、大規模データが限られてきたこともあって、そうした手法を採用した研究は、筆者らの知る限り、Inamura *et al.* [14] に限られている。

本稿では、機械学習の分野で広く知られたふたつの手法を用いる。ひとつは、ランダム・フォレストと呼ばれる手法で、機械学習の分野では予測のパフォーマンスがきわめて高いことで知られている。ランダム・フォレストは、特定の関数形を仮定しないため、経済学の実証分析で多用されるパネルデータを用いた回帰分析やベクトル自己回帰モデルなどと比べて、先験的に課す制約が圧倒的に少ない。たとえば、通常回帰分析では、特定の関数形を仮定するため、説明変数の数が多くなるとパラメータの数が多くなり、ともすると適切な推定が困難になるが、ランダム・フォレストはノンパラメトリックな手法であるため、そうした「次元の呪い」と呼ばれる問題に悩まされることなく、きわめて多くの変数を説明変数として利用することができる。

もうひとつは、ベイジアン・ネットワークと呼ばれる手法である。経済学では、グレ

ンジャー因果性テストや DID 推定 (difference in differences) などの手法を用いて変数間の因果構造を明らかにしようとすることが多い。これらの手法は、時系列方向に十分に長い期間のデータが必要であったり、データが一定の前提条件を満たすことを要求する。もっとも、多くの場合、そうした理想的な環境は整っていない。ベイジアン・ネットワークは、時間に関する情報を用いることなく、また、変数間に強い仮定を設けることもなく、変数間の相関構造から因果構造を推定することができる。

本稿の貢献は、機械学習の手法を用いて企業のインフレ予想形成メカニズムにアプローチしたことにより、特定の理論モデルに依拠しない、その意味において頑健な事実を発見したことである。「機械」が発見した重要な事実は、次の四点である。第一に、「物価全般」予想は、各企業に共通した何らかのマクロ変数と密接に関連している。中央銀行にとって、この発見は、金融政策がこのマクロ変数に働きかけられるのであれば、金融政策が「物価全般」予想にも働きかけられる可能性があることを示唆している。

第二に、「物価全般」「自社の販売価格」いずれの予想でも、GDP ギャップに関連するような実物変数の重要度は低い。この点は、マクロのフィリップス曲線において、GDP ギャップにかかる係数が小さいことと整合的である。また、本稿のデータでは検証が困難ながら、近年のフィリップス曲線のフラット化を示唆している可能性もある。

第三に、「物価全般」と「自社の販売価格」とでは、予想形成メカニズムが異なっている。たとえば、マクロ変数は、「物価全般」予想の形成において、より重要度が高い。同様に、企業規模も「物価全般」予想の形成において、より重要な役割を果たしているとみられる。このように、本稿は、「物価全般」と「自社の販売価格」の予想形成メカニズムの違いを示唆するよういくつかの証拠を提示する。中央銀行がインフレーション・ターゲット政策を採用する際、多くの場合、そのターゲットは、「物価全般」である。これを踏まえると、「物価全般」と「自社の販売価格」の予想形成メカニズムの違いは、少なくとも中央銀行にとっては重要な意味がある。

第四に、長期のインフレ予想は、各企業に固有のミクロ変数の影響を受けにくい。宇野・永沼・原 [1] は、長期のインフレ予想の改定頻度が短期より頻繁であることを報告しているが、ここでの発見とあわせて考えると、長期のインフレ予想のより頻繁な改定は、各企業に共通した何らかのマクロ変数によって引き起こされていた可能性が高い。

本稿の構成は、以下のとおりである。2 節では、関連する先行研究を整理し、本稿の立ち位置を明確にする。3 節では、本稿で用いるデータについて、分析上の留意点を確認する。4 節において、本稿で用いる機械学習の手法について確認したあと、続く 5 節で、学習の結果を報告する。最後の 6 節は結論である。

## 2 関連研究

本稿は、宇野・永沼・原 [1] と相互に補完的な関係にある。ここでは、本稿と宇野・永沼・原 [1] との関係を確認したあと、手法面で本稿と関連する先行研究を整理する。

### 2.1 宇野・永沼・原 [1] との関係

本稿は、宇野・永沼・原 [1] と共通した問題意識にもとづいている。また、分析に用いるデータも同じものである。もっとも、分析のアプローチはまったく異なっている。本稿の狙いは、宇野・永沼・原 [1] と異なる方向からアプローチすることにより、相互に補完的な知見を得ることにある。

宇野・永沼・原 [1] は、企業のインフレ予想の水準と予想改定パターンに関するいくつかの重要な事実を発見している。第一に、企業のインフレ予想には下方硬直性があること、第二に、企業のインフレ予想は、業種間より企業規模間での差異が大きいこと、第三に、企業のインフレ予想の期間構造をみると、3年後以降はほぼ不変であること、第四に、企業規模や業種を問わず、年限が長くなるほど、インフレ予想の改定頻度が高くなることを指摘している。また、宇野・永沼・原 [1] は、企業のインフレ予想の形成には、Mankiw and Reis [18] のシンプルな粘着情報モデルと整合的な面があることも同時に指摘している。特に、そこで初めて明らかにされた企業のインフレ予想の改定頻度は、先行研究が報告してきたエコノミストや家計の予想改定頻度に比べてずっと低く（予想が粘着的で）、Mankiw *et al.* [19] がカリブレーションにおいて想定していた値にかなり近いものであった。これらの発見により、宇野・永沼・原 [1] は、企業のインフレ予想に働きかけるような金融政策が、相応に時間がかかるとしても、有効に機能し得るとの含意を得ている。

宇野・永沼・原 [1] のアプローチは、粘着情報モデルという「フィルター」を通じて企業のインフレ予想形成を理解しようとするもので、経済学においては、ごく標準的なアプローチであるといえる。そのアプローチのメリットは、合理的な企業行動などの前提を受け入れさえすれば、企業のインフレ予想形成行動を論理的に矛盾なく説明できることにある。反面、デメリットのひとつとして、定量的な予測力ないし説明力が必ずしも高くないという点をあげることができる。たとえば、先行きのインフレ予想について、粘着情報モデルが十分に精度の高い予測を行ってくれるわけでは必ずしもない。こうした際、インフレ予想についての洞察を深めるためのひとつの有用なアプローチは、一旦、理論モデルという「フィルター」を外し、できる限り先験的な仮定を設けず、データに語らせるかたちで事実を集めてみることだと考えられる。

こうしたことを踏まえ、本稿は、機械学習によるアプローチを採用する。本稿のようなアプローチに対して、伝統的な経済学サイドからは、「ルーカス批判」が寄せられるかもしれない。すなわち、得られた分析結果は、「機械」が学習した「経験則」にもとづいており、学習されたパラメータが構造的なものではないとの指摘である。そうした批判があったとしても、企業のインフレ予想に関しては実証的な知見が十分に蓄積されていないことから、特定の理論モデルに依拠しないかたちでの事実整理を行うことは、少なくとも現時点では、意義が大きいと考えられる。このアプローチによって得られた発見のいくつかは、宇野・永沼・原 [1] の発見と整合的なものである。また、別のいくつかは、宇野・永沼・原 [1] にはない、本稿に固有の発見で、企業のインフレ予想形成についての新たな見方を提供するものである。

## 2.2 手法面で関連する研究

ここでは、機械学習という手法の面で本稿と関連する先行研究を整理しておく。Varian [26] や Einav and Levin [13] が述べるように、機械学習は、近年の大規模データの利用可能性の高まりとも相まって、経済分析における新たなツールとして期待されている。岡崎・敦賀 [2] は、大規模データや機械学習の手法を用いた、近年のさまざまな分野の研究を包括的に整理している。岡崎・敦賀 [2] によれば、これまでの研究は、(1) 速報性の高さや、各種経済主体の経済活動を細かく補足することができるという大規模データの特徴を活かして、経済・物価動向の把握を試みる方向性と、(2) 経済理論の実証、とりわけ特定の政策が経済変数に与える効果や構造的な因果関係の実証に用いる方向性、とに分けることができる。本稿は、後者に属している。

後者の領域においては、現時点での研究の蓄積はさほど多くない。Bajari *et al.* [5] は、ポテトチップスの需要量について、線形回帰やロジットモデルなど伝統的な計量経済モデルと、機械学習の分野でよく知られた LASSO、サポート・ベクトル・マシン、ランダム・フォレスト、バギングなどのモデルの予測力を比較し<sup>1</sup>、ランダム・フォレストの予測力がもっとも高いことを報告している。また、金融政策関連では、Hansen *et al.* [17] が、トピックモデルを用いたテキスト分析にもとづいて中央銀行の情報発信について議論している<sup>2</sup>。もっとも、インフレ予想に関しては、大規模データが限られてきたこともあって、機械学習の手法を援用した研究は、筆者らの知る限り、Inamura *et al.* [14] に限られている。Inamura *et al.* [14] は、本稿と同じ短観の個票データを用いて、ベイジアン・ネットワークの学習を行い、「自社の販売価格」予想が販売価格の実績から影響を受けることなどを

<sup>1</sup>これらの手法についての詳細は、杉山 [3] を参照。

<sup>2</sup>トピックモデルなどテキスト分析についての詳細は、Bholat *et al.* [6] を参照。

指摘している<sup>3</sup>。

### 3 データ

本稿で用いるデータは、宇野・永沼・原 [1] と同じ短観の個票データである。宇野・永沼・原 [1] は、「物価見通し」に関するデータだけを用いたが、本稿は、それに加えて、主観的な判断に関する質的データも利用する<sup>4</sup>。ここでは、宇野・永沼・原 [1] との相違点である主観的な判断項目について、分析上の留意点を確認する。

主観的な判断項目には、(1) 自社の業況、(2) 自社が属する業界の国内製商品・サービス需給、(3) 自社が属する業界の海外製商品需給、(4) 自社の在庫および (5) 自社が属する業界の流通在庫水準、(6) 自社の生産・営業用設備および (7) 雇用人員の過剰感、(8) 自社の資金繰り、(9) 金融機関の貸出態度、(10) 借入金利水準、(11) CP の発行環境、(12) 自社の販売価格および (13) 仕入価格、の計 13 項目が存在し、ほとんどすべての項目において、「最近」と「先行き」のふたつの時点についての回答を求めている。「最近」は調査票記入時点の判断を求めているため、各企業が実際に直面した事態に対する評価である。他方、「先行き」は、3 か月後の次回調査時点における判断を求めている。

「物価見通し」の項目と混同しがちなのは、自社の販売価格の「先行き」である。この判断項目は、3 か月後の自社の販売価格を「上昇」「もちあい」「下落」の三つの選択肢から回答するものである。「物価見通し」の項目における自社の販売価格は、1 年後、3 年後、5 年後の販売価格を「+20%程度以上」「+15%程度」など 10 個の選択肢から定量的な水準を回答させるものである。選択肢の種類および数こそ違うものの、先行きの「自社の販売価格」について回答を求めるという意味では、これらはよく似た情報を備えている。すなわち、「自社の販売価格」予想には、3 か月後、1 年後、3 年後、5 年後という 4 種類のインフレ予想が存在すると考えることができる。

主観的な判断項目はいずれも、三つの選択肢から回答を求めている。他方、「物価見通し」については、「自社の販売価格」で 9 個、「物価全般」で 10 個の選択肢が用意されている<sup>5</sup>。この変数間のカテゴリー数の違いは、変数間の関係を学習する際に、何らかの影

<sup>3</sup> データを用いた実証研究ではないが、Spiegler [24] は、ベイジアン・ネットワークを用いて、合理的な予想形成プロセスを描写している。

<sup>4</sup> 短観には、大きく分けて三種類の情報がある。第一は、業況や需給バランスなどの主観的な判断を三つの選択肢から選んで回答させる質的データ、第二は、設備投資や売上などの事業計画を実数で回答させる量的データ、最後の第三は、1 年後、3 年後、5 年後の物価見通しを複数の選択肢の中から回答させる量的データである。本稿では、このうち第一と第三のカテゴリーのデータを用いている。なお、個票データへのアクセスはごく限られた一部の人間が行った。そのうえで、分析作業は外部との接続が完全に遮断されたスタンドアロン端末において行っている。

<sup>5</sup> 「自社の販売価格」には「分からない」との選択肢を含めると 10 個、「物価全般」には「イメージを持つ

響を及ぼす可能性がある。もっとも、主観的な判断項目に関する真の企業数分布が先験的に明らかでない以上、そうしたカテゴリー数の違いがもたらすバイアスの有無について確たることはいえない。

## 4 学習手法

「機械」に企業のインフレ予想形成行動を学習させるために、本稿では、次のふたつのステップを踏む。第一のステップでは、企業のインフレ予想形成と関係のある変数を機械的に探索する。ここでは、ランダム・フォレストと呼ばれる、機械学習の分野でよく知られたアンサンブル学習の手法を用いる。ランダム・フォレストは、いくつかの主要な機械学習の手法と比べて予測のパフォーマンスが高いことが知られている。第二のステップでは、第一のステップでインフレ予想と関係があるとされた変数について、それらの変数の間の因果構造を学習させる。このステップでは、ベイジアン・ネットワークと呼ばれる、確率的グラフィカルモデルを用いる。この手法も機械学習の分野ではよく知られている。3節でみたように、本稿で用いる短観の個票データは、時系列方向に11四半期分しかないため、グレンジャー因果性テストのような時系列データから因果構造を明らかにする手法を適用することはできない。ベイジアン・ネットワークは、時間に関する情報を用いることなく因果構造の一部を学習することができる。

### 4.1 ランダム・フォレスト

ランダム・フォレストは、Breiman [9] によって提示されたアンサンブル学習の手法である。アンサンブル学習とは、性能の低い学習器を組み合わせることで性能の高い学習器を作成する方法で、ランダム・フォレストの場合、性能の低い学習器は、回帰木 (regression trees) と呼ばれる手法である。

**回帰木** 経済学において用いられる回帰分析の多くは、サンプル全体の予測誤差の集計値を最小化しようとする。これと対照的に、回帰木は、サンプルをふたつに分割することを繰り返しながら、徐々に予測誤差を小さくしていく。今、企業のインフレ予想に関する予測誤差の分散を  $\hat{\sigma}^2$  とし、 $l$  個の説明変数を  $x_k (k = 1, \dots, l)$  とする。回帰木は、以下の目的関数を最小化するような説明変数  $x_k$  とサンプルの分割点  $s_k$  を選ぶ。

$$\hat{\sigma}^2(n_L | x_k, s_k) + \hat{\sigma}^2(n_R | x_k, s_k)$$

ていない」との選択肢を含めると13個の選択肢がある。



ここで、 $n_L$  と  $n_R$  は、ふたつに分割されたサンプルのそれぞれのサンプル数を表している。最初の分割が行われたあと、分割されたふたつのサンプルにおいて、上記の目的関数を最小化するような説明変数  $x_k$  とサンプルの分割点  $s_k$  を選ぶことを繰り返していく。

たとえば、被説明変数が「物価全般」1年後予想で、説明変数が業況判断 DI と販売価格 DI のふたつであるとする。回帰木の最初の分割手順は次のとおりである。まず、業況判断を「良い」と答えた企業とそれ以外に分け、それぞれのグループの「物価全般」1年後予想の平均値を計算する。次に、それぞれのグループにおける各企業の「物価全般」1年後予想について、それぞれのグループの平均値からの乖離を計算して、その乖離の二乗値を集計する。これをすべての変数および選択肢について行う。たとえば、業況を「さほど良くない」と答えた企業とそれ以外に分け、同じ作業を行う。業況判断 DI と販売価格 DI には、それぞれ三つの選択肢があるため、集計誤差は、全部で六通り計算することができる。このうち、もっとも集計誤差の小さい説明変数と分割点の組み合わせが最初の分割点となる。最初の分割が行われたあと、分割されたそれぞれのグループにおいて、引き続き、業況判断 DI と販売価格 DI のふたつの説明変数を用いて同じ作業が繰り返される。それぞれグループにおいて、すべての企業の業況判断 DI と販売価格 DI の回答が同じになれば、それ以上の分割ができなくなるため、回帰木の学習が終了する。この手続きから明らかなように、分割を行う際にどの説明変数を候補として用いるかによって、学習の結果は変わり得る。

やや細くなるが、上記の例では、説明変数である DI を連続変数でなくカテゴリー変数として扱っている点に留意が必要である。すなわち、分割に際して、業況についての「1: 良い、2: さほど良くない、3: 悪い」という選択肢の順序を入れ替えることを認めている。これを連続変数とみなすことは、選択肢の順序を入れ替えないことを意味するため、分割は二通りとなる。他方、カテゴリー変数とみなせば、三通りの分割があり得る。上記の例において、業況を「2: さほど良くない」と答えた企業とそれ以外に分けるという作業は、この変数をカテゴリー変数とみなしていることを意味している。

回帰木は、説明変数の間に相互作用があるような場合には、とりわけ有用な手法である。すなわち、通常の回帰分析では、説明変数が多い場合に説明変数間の相互作用まで考慮すると推定の自由度が失われてしまうが、回帰木は、こうした問題を回避することができる。この回帰木の強みを生かせば、企業のインフレ予想がどの変数とどのように関係しているのか、非線形の関係まで視野に入れながら、より正確に特定することができると思われる。もっとも、よく知られているように、回帰木には、バイアスが少ない一方で、分散が大きいという欠点がある (bias-variance tradeoff)。学習器の分散が大きくなるのは、データのもつノイズを拾いすぎているため、機械学習の分野では、過学習 (over-fitting)

の問題と呼ばれている。

ランダム・フォレスト Breiman [9] は、アンサンブル学習によって、回帰木の弱みである過学習を回避できることを示した。具体的には、ひとつのデータをリサンプリングすることによって複数の回帰木を学習させ、以下のように、それらの平均値をとることで分散を小さくできることを示した。

$$RF(X) = \frac{1}{B} \sum_b^B T_b(X)$$

ここで、 $X$  は、説明変数  $x_k (k = 1, \dots, l)$  からなるベクトル、 $RF(X)$  は、ランダム・フォレスト学習器、 $T_b(X)$  は、サンプルの分割に用いる説明変数をランダムに選択した回帰木学習器、 $B$  はリサンプリング回数である。ランダム・フォレストは、その呼び名のとおり、 $l$  個の説明変数をすべて使うわけではなく、サンプルの分割のたびに、 $l$  個の中からランダムにいくつかの説明変数を選ぶ<sup>6</sup>。これによって、リサンプリングによって同じような学習結果ばかりが得られてしまうことを回避し、高い予測力を得ることに成功している。

**変数重要度 (variable importance)** 本稿の関心は、ランダム・フォレストの予測力というより、むしろ、企業のインフレ予想と関係のある説明変数を探索することにある。この点、回帰木やランダム・フォレストは、通常回帰分析のようなパラメトリックな手法ではないため、被説明変数と説明変数の間の関係が統計的に有意かどうかを検定することはできない。それでは、どのように企業のインフレ予想と関係のある説明変数を探し出せるだろうか。

本稿では、Breiman [9] にならい、変数重要度 (variable importance) と呼ばれる指標を用いて各説明変数の重要度を評価する。説明変数  $x_k$  の変数重要度は、 $x_k$  の観測値をランダムに並べ替えた場合に予測誤差がどの程度大きくなるかを計測したものである。例として、被説明変数が「物価全般」1年後予想、説明変数が業況判断 DI、企業数は企業 A から企業 E まで 5 社の場合を考える。説明変数の観測値が「良い、悪い、悪い、良い、さほど良くない」、被説明変数の観測値が「2%、0%、0%、2%、1%」だったとしよう。このとき、回帰木は、業況判断 DI が「良い」ならば「2%」、「悪い」ならば「0%」、「さほど良くない」ならば「1%」と学習するため、予測誤差はゼロである<sup>7</sup>。今、説明変数の観測値

<sup>6</sup>本稿では、 $l$  個の説明変数のプールの中から、 $\sqrt{l}$  個の説明変数を選んでいる。なお、 $l$  個すべての説明変数を使う場合には、ランダム・フォレストではなく、バギング (bagging) と呼ぶ (Breiman [8])。

<sup>7</sup>正確に言えば、ランダム・フォレストでは、データの一部を学習に使わず、標本外予測を行うためのテストデータとして利用する。そのテストデータで予測を行う際の標本外予測の誤差がランダム・フォレスト本来の意味での予測誤差である。この例では、説明を簡単にするために、標本内予測の誤差を予測誤差と呼んでいる。

をランダムに並べ替え、たとえば、「悪い、さほど良くない、悪い、良い、良い」となったとする。被説明変数の観測値は、引き続き、「2%、0%、0%、2%、1%」である。このとき、回帰木は、「さほど良くない」ならば「0%」と学習できるが、「良い」と「悪い」については、プラスの予測誤差が生じる。この説明変数の観測値の並べ替え前後での予測誤差の変化がここでの変数重要度である。

こうした作業をすべての説明変数について行ったうえで、予測誤差がもっとも大きくなる変数をもっとも重要度が高いと評価する。逆に、観測値をランダムに並べ替えても予測誤差がさほど変化しないのであれば、その変数は、予測において重要な役割を担っていないと考える<sup>8</sup>。

## 4.2 ベイジアン・ネットワーク

ランダム・フォレストは、企業のインフレ予想と関係のある変数を探し出すうえでは強力な学習器である。もっとも、変数間の因果については何も教えてくれない。たとえば、インフレ予想と販売価格の間に何らかの関係が認められた場合、どちらが原因でどちらが結果なのか、ランダム・フォレストの学習結果から明らかにすることはできない。インフレ予想の変化によって販売価格が変化したのか、あるいは逆に、販売価格の変化によってインフレ予想が変化したのか、これらは金融政策に対して異なる含意をもつ。したがって、インフレ予想を巡る変数間の因果構造を明らかにすることはきわめて重要な作業である。

ベイジアン・ネットワークは、有向非循環グラフ (directed acyclic graph: DAG) を用いて確率変数の間の同時分布を記述する手法で、変数間の因果構造を描写することができる。たとえば、企業のインフレ予想を  $E$  として、 $X$  と  $Y$  をそれぞれ  $E$  に影響を与える外生的な確率変数であるとする。このとき、三つの確率変数の同時分布は、以下のように書ける。

$$\Pr(X, Y, E) = \Pr(E | X, Y) \Pr(X) \Pr(Y)$$

この同時分布から周辺分布と条件付分布の積への因数分解は、有向非循環グラフを用いて図1のように表現できる。ここで、有向非循環グラフに関するいくつかの基本的な用語を確認しておく。各変数を表す丸をノード、ノードを結ぶ線をエッジと呼ぶ。グラフは、エッジによって結びつけられたノードの集まりで、ネットワークとも呼ばれる。エッジにおける矢印の方向を無視してグラフをみたものをスケルトンと呼んでいる。ふたつのノ

<sup>8</sup>観測値をランダムに並べ替えた結果、予測誤差が小さくなる場合もある。この場合、変数重要度はマイナスとなり、当該変数は、予測において有害な影響を及ぼしている可能性が高い。

ドがエッジによって結ばれている状態を隣接 (adjacent) しているといい、隣接しているふたつのノードについて、矢印の発信元を親、発信先を子と呼ぶ。図1では、 $X$ と $Y$ が $E$ の親であり、 $E$ は $X$ と $Y$ の子である。最後に、図1のように、ある三つのノードについて、それぞれに隣接していないふたつの親が共通したひとつの子をもつとき、その構造をコライダー (collider) と呼んでいる。

**PC アルゴリズム** 次に、有向非循環グラフで表現される因果構造を実際のデータから学習するアルゴリズムについて説明する。因果構造の学習には、大別してふたつのアプローチが存在する。ひとつは、発見的アプローチで、ベイジアン情報量基準など何らかの統計量を最大化するような因果構造を探し出すものである<sup>9</sup>。もうひとつは、制約ベースアプローチと呼ばれる方法で、各ノード間の条件付独立を統計的に検定することを通じて因果構造を学習するものである。PC アルゴリズムは、制約ベースアプローチにおいてよく用いられるアルゴリズムで、本稿でもこれを用いて因果構造を学習する。

PC アルゴリズムは、Pearl [21] が示した、有向分離 (d-separation) と呼ばれる概念に立脚している<sup>10</sup>。PC アルゴリズムは、大きく分けて、ふたつのステップからなる<sup>11</sup>。第一のステップは、有向非循環グラフのスケルトンの学習である。まず、すべてのノードをほかのすべてのノードとエッジで結ぶ。次に、あるふたつのノード  $X$  と  $Y$  を結ぶエッジについて、隣接する任意のノードからなる集合  $S$  を条件とした条件付独立  $X \perp Y \mid S$  の検定を行う<sup>12</sup>。条件付独立が検出されれば、 $X$  と  $Y$  は有向分離されていることを意味するため、任意の集合  $S$  について検定を行っていき、 $X \perp Y \mid S$  となる  $S$  をひとつでも発見できれば、その時点で  $X$  と  $Y$  を結ぶエッジを外す。この手続きの背後にある基本的な考え方は、もし  $X$  と  $Y$  の間に直接的な結びつきがあるのであれば、隣接するすべてのノードを経由する経路を遮断したとしても、 $X$  と  $Y$  の間に相関がみられるはずだということである。逆にいえば、ある隣接するノードの集合  $S$  で条件付けた場合に、 $X$  と  $Y$  が独立になるのであれば、 $X$  と  $Y$  は集合  $S$  を経由して結びついており、直接的な結びつきはないと考える。この手続きをすべてのエッジに対して行くと、スケルトンが学習される。

第二のステップでは、第一のステップで得られたスケルトンを所与として、グラフの因果構造を学習する。このステップでも、条件付独立の検定によってあるノードが別のあるノードから有向分離されているか否かを判定する。これによって因果構造の一部が明らかになる。具体的には、グラフの中から、スケルトンが  $X - E - Y$  となっている三つの

<sup>9</sup>たとえば、Chickering [10] の GES アルゴリズム (Greedy Equivalence Search algorithm) などがこれにあたる。

<sup>10</sup>有向分離についての詳細は、Pearl [21, 22] や Bishop [7] を参照。

<sup>11</sup>PC アルゴリズムについての詳細は、Spirtes *et al.* [25] を参照。

<sup>12</sup>集合  $S$  は、空集合も含む。

ノードを選ぶ。  $E$  で条件付けた場合の  $X$  と  $Y$  の条件付独立を検定すれば、  $X$  が  $Y$  から有向分離されているかを判定することができる。  $X$  が  $Y$  から有向分離されていれば、この三つのノードの間の因果構造は、  $X \rightarrow E \rightarrow Y$ 、  $X \leftarrow E \leftarrow Y$ 、  $X \leftarrow E \rightarrow Y$  のいずれかである。他方、  $X$  が  $Y$  から有向分離されていない場合、これらは図1のようなコライダーである。すなわち、  $X - E - Y$  となっている三つのノードにおける条件付独立の検定によってコライダーを探し出すことができる。ただし逆にいえば、コライダーでない場合には、  $X \rightarrow E \rightarrow Y$ 、  $X \leftarrow E \leftarrow Y$ 、  $X \leftarrow E \rightarrow Y$  のいずれが真の因果構造なのかを識別することはできない<sup>13</sup>。このように、PCアルゴリズムは、真の因果構造の一部しか明らかにしない点には留意が必要である。

**コミュニティ抽出** 最後に、因果構造の学習結果を所与として、そのネットワークに内在するコミュニティ構造を抽出する。本稿では、Newman and Girvan [20] によって提示された、 $Q$  の最大化によるコミュニティ構造の抽出を行う。Newman and Girvan [20] は、ネットワークにおけるコミュニティをグループ内が密でグループ間が疎なくつかのノードの集まりと定義したうえで、あるネットワークからコミュニティ構造を抽出する方法として、 $Q$  と呼ばれるモジュラリティ指標を最大化するように、各ノードをグループ分けすることを提案した。 $Q$  は0と1の間をとる指標で、次のように定義されている。

$$Q = \frac{1}{2m} \sum_{i,j} \left[ A_{i,j} - \frac{k_i k_j}{2m} \right] \delta(c_i, c_j)$$

ここで、 $A_{i,j}$  はネットワークを隣接行列として表現した場合の  $i$  行  $j$  列の要素で、ふたつのノード  $i$  と  $j$  が隣接していれば1、そうでなければゼロをとる。 $m$  は、ネットワーク内のすべてのエッジ数、 $k_i$  はノード  $i$  のエッジ数、 $c_i$  はノード  $i$  のコミュニティ、 $\delta(c_i, c_j)$  は、 $c_i = c_j$  で1をとり、そのほかの場合にはゼロをとる関数である。これらの定義から、 $[A_{i,j} - k_i k_j / 2m] \delta(c_i, c_j)$  は、ふたつのノード  $i$  と  $j$  が同じコミュニティにあり、かつ隣接している場合にプラスの値をとることがわかる。 $k_i k_j / 2m$  は、ふたつのノード  $i$  と  $j$  をランダムに結んだ場合のエッジ数であるため、コミュニティ内のエッジの数がランダムにノードを結んだ場合のエッジの数と同じであれば、 $Q$  はゼロをとる。

<sup>13</sup>この識別不能性は、直観的にいえば、 $X \rightarrow E \rightarrow Y$ 、 $X \leftarrow E \leftarrow Y$ 、 $X \leftarrow E \rightarrow Y$  という三つのグラフの同時分布が同じであることに起因している。

## 5 学習結果

本節では、学習の結果を報告する。学習には、オープンソースのソフトウェアである R を用いた<sup>14</sup>。

### 5.1 ランダム・フォレストの変数重要度

図 2 と図 3 は、ランダム・フォレストによる学習の結果である。回帰木の学習回数は 1,000 回とした<sup>15</sup>。説明変数は、各年限の「物価全般」予想と「自社の販売価格」予想、業況などすべての主観的な判断項目 (DI)<sup>16</sup>、資本金別の企業規模のほか、各企業に共通のマクロ変数として、GDP ギャップ、原油価格、CPI コア (除く生鮮・エネルギー) 前年比、時間の四つを採用した<sup>17</sup>。

パネルデータを用いた通常の回帰分析の場合、各企業に共通した時間ダミーを説明変数として採用すると、それ以外のマクロ変数を推定に利用することができない。これは、マクロ変数間での観測値の差が時間ダミーにかかる係数に吸収されるためである。回帰木は、係数を推定するわけではないため、時間の情報と同時にマクロ変数を扱うことが可能である。ただし、サンプル期間中の変動が一方向に偏っているようなマクロ変数の場合には、時間とよく似た変数重要度になってしまう。

「物価全般」予想 図 2 は、「物価全般」予想の形成における変数重要度を示している。この結果から、次の四点を指摘できる。第一に、いずれの年限でも、ある年限の「物価全般」予想に対して、もっとも重要な変数は、異なる年限の「物価全般」予想である。このことは、企業のインフレ予想に慣性が働いていることを示唆している。ただし、「物価全般」1 年後予想について仔細にみると、「物価全般」3 年後予想の重要度がもっとも高い一方、「物価全般」5 年後予想の重要度は著しく低い。宇野・永沼・原 [1] は、本稿と同じデータを用いて、「物価全般」の 3 年後予想と 5 年後予想を同じ伸び率で回答する先が 70% を上回っていることを指摘しているが、ここでの結果とあわせて考えると、3 年後予想と 5 年後予想を異なる伸び率で回答している 30% 弱の企業が、各企業の 1 年後予想を説明する

<sup>14</sup>R のコードは、補論 A 節を参照。

<sup>15</sup>学習回数を 10 倍の 10,000 回としても、結果はほとんど変わらない。

<sup>16</sup>主観的な判断項目のうち、「CP の発行環境」については、資本金 10 億円以上の大企業のみにも回答を求めたため、分析から除外している。

<sup>17</sup>各企業に共通のマクロ変数とインフレ予想に関する変数は連続変数として扱い、主観的な判断項目および資本金別の企業規模については、カテゴリー変数として扱った。ただし、すべての変数を連続変数とした場合でも、結果は大きく異なる。

うえで、決定的に重要な情報を有していることが示唆される。なお、ある年限の「物価全般」予想に対して、同じ年限の「自社の販売価格」予想の重要度も高い。

第二に、いずれの年限でも、インフレ予想以外では、CPI コア以外のマクロ変数、すなわち、時間、原油価格、GDP ギャップの重要度が総じて高い。それらの中では、時間と原油価格の重要度が高く、GDP ギャップの重要度はいくらか低い。これは、Coibion and Gorodnichenko [11] が主張するように、原油価格がインフレ予想と関係していることを示唆している。ただし、原油価格は、サンプル期間中ほぼ一貫して低下していたため、時間との識別がやや困難になっている点に留意が必要である。すなわち、本稿のサンプル期間である 2014 年 3 月から 2016 年 9 月までの各企業に共通した要因、たとえば、2014 年 4 月の消費税率引き上げの影響などを「原油価格」の影響であると誤って捉えている可能性もある。GDP ギャップとの関連では、雇用過不足、設備過不足、国内需給といった変数の重要度もおしなべて低い。これらは、マクロのフィリップス曲線において、GDP ギャップにかかる係数が小さいことと整合的である。また、本稿のデータが 2014 年以降であることから定量的な検証は困難だが、近年のフィリップス曲線のフラット化を示唆している可能性もある。

第三に、いずれの年限でも、インフレ予想とマクロ変数以外では、企業規模の重要度が高い。インフレ予想に企業規模間で差異があることについては、既に、宇野・永沼・原 [1] が指摘している。ただし、ほかのさまざまな変数と比較した場合に、企業規模の重要度がこれほど高い点は特筆に値する。なお、ここでの企業規模は資本金にもとづいた分類であるが、雇用者数で企業規模を定義した場合でも結果は変わらない。

「自社の販売価格」予想 図 3 は、「自社の販売価格」予想の形成における変数重要度を示している。この結果から、次の四点を指摘できる。第一に、いずれの年限でも、ある年限の「自社の販売価格」予想に対して、もっとも重要な変数は、異なる年限の「自社の販売価格」予想である。また、ある年限の「自社の販売価格」予想に対して、同じ年限の「物価全般」予想の重要度も高い。これは、「物価全般」予想に関して得られた結果と平行である。

第二に、インフレ予想以外の変数に絞ってみると、いずれの年限でも、マクロ変数の重要度は、「物価全般」に比べて低めである。「自社の販売価格」予想を回答させることから、各企業に共通したマクロ変数の重要度が「物価全般」予想に比べて低くなることは、ある程度自明である。むしろ、「自社の販売価格」予想である割には、マクロ変数が重要な役割を果たしているともいえる。なお、マクロ変数の中で、時間と原油価格の重要度が相対的に高く、GDP ギャップの重要度がいくらか低いという点は、「物価全般」予想

と同様である。

第三に、いずれの年限でみても、企業規模の重要度は、「物価全般」に比べて低めである。宇野・永沼・原 [1] が指摘したように、企業のインフレ予想形成がシンプルな粘着情報モデルと整合的だとすると、企業規模によって予想形成にかかるコストが異なっている可能性がある。これを踏まえると、「自社の販売価格」予想の形成において、企業規模の重要度が「物価全般」より低いという事実は、「自社の販売価格」予想の形成にかかる企業規模間のコスト差が「物価全般」予想ほど大きくないことを示唆している。

## 5.2 ベイジアン・ネットワークの学習結果

5.1 節のランダム・フォレストの学習結果をみると、いくつかの主観的な判断項目は、インフレ予想の形成に明らかに重要な役割を果たしていない。ここでは、変数重要度が低い九つの変数、「設備過不足(最近、先行き)」、「貸出態度」、「借入金利(最近、先行き)」、「在庫水準」、「海外需給(最近、先行き)」、「流通在庫水準」をベイジアン・ネットワークの学習から除外する。また、四つのマクロ変数は、各企業にとって明らかに外生的であるため、これも除外する。なお、PC アルゴリズムにおける条件付独立の検定の有意水準は 5%とした。

図 4 は、ベイジアン・ネットワークの学習結果である<sup>18</sup>。結果について議論する前に、ここでの描画のルールを確認しておく。ノードの大きさは、当該ノードに結ばれているエッジ数、色はコミュニティを表している。エッジには直線とカーブしたものの二種類がある。直線のエッジには矢印が付いており、矢印は因果の向き、その色は親ノードと同じ色にしている。また、カーブしたエッジは双方向の因果が存在することを意味しており、両ノードの色を混ぜた色で描いている。レイアウト(ノードの位置)は、ForceAtlas アルゴリズムを用いて決定した<sup>19</sup>。

表 1 は、ネットワークの中からインフレ予想と直接的な結びつきがある変数だけを取り出したものである。図 4 と表 1 の結果から、次の五点を指摘できる。第一に、企業のインフレ予想は、それだけで独自のコミュニティを形成している。これは、ランダム・フォレストの変数重要度の結果と整合的で、「物価全般」「自社の販売価格」予想のいずれについても、インフレ予想は相互に強く結びついていることを示唆している。さらに、表 1 をみると、原因と結果のいずれについても、実物関連の変数が少ないことを指摘することができる。この点、Inamura *et al.* [14] も指摘しているように、インフレ予想を含む価格関連

<sup>18</sup> 調査回ごとに学習を行うと、いくつかの変数を除くだけで結果が大きく変わるなど安定した結果が得られなかったため、学習は、すべての調査回をプールしたサンプルで行っている。

<sup>19</sup> ForceAtlas アルゴリズムについては、Jacomy *et al.* [15] を参照。



の変数と実物関連の変数の結びつきが弱いことが示唆される。この点も、ランダム・ウォークの変数重要度において、GDP ギャップに関連した変数の重要度が低かったことと整合的である。

第二に、1年後という短期のインフレ予想は、主観的な判断項目と多くの結びつきをもっている一方、3年後や5年後といった中長期のインフレ予想は、そうした結びつきが相対的に少ない。これは、「物価全般」「自社の販売価格」いずれにも当てはまる。このことは、3年後や5年後といった中長期のインフレ予想は、このネットワークからみた外生要因によって変動しやすいことを示唆している。宇野・永沼・原 [1] は、本稿と同じデータを用いて、予想の年限が長いほど予想改定頻度が高いことを報告している。ここでの結果とあわせて考えると、3年後や5年後といった中長期のインフレ予想のより頻繁な改定は、各企業にとって外生的なマクロ変数によって生じていた可能性が高い。

第三に、企業のインフレ予想に対して直接的な影響を与える変数は、「物価全般」予想では、「資金繰り」「仕入価格(最近)」「販売価格(最近)」、「自社の販売価格」予想では、「販売価格(先行き)」「企業規模」である(表1)<sup>20</sup>。「物価全般」予想が仕入価格や販売価格の実績に影響を受けるという事実は、予想が適合的に形成されていることを示唆している。特に、販売価格の実績は、「物価全般」の5年後予想に影響を与えており、この点は、西野ほか [4] の指摘とも整合的である。他方、「自社の販売価格」予想には、販売価格の実績でなく先行きが影響を与えており、適合的な予想形成を示唆するような証拠は見当たらない<sup>21</sup>。

第四に、企業のインフレ予想から直接的な影響を受ける変数は、「物価全般」予想では、「国内需給(最近)」「雇用過不足(最近)」、「自社の販売価格」予想では、「雇用過不足(最近、先行き)」である(表1)。短観では、たとえば雇用過不足については、「適正」といった選択肢を中心に、「過剰」と「不足」についての判断を三択で問う<sup>22</sup>。したがって、ある時点での企業の雇用水準を所与とすると、インフレ予想が雇用過不足の判断に影響を与えるということは、インフレ予想の水準によって、その企業が「適正」と考える雇用水準が変化することを示唆している<sup>23</sup>。

第五に、Spiegler [24] は、「合理的予想形成仮説」が成り立つことは、有向非循環グラフにコライダーが存在しないことと同値であることを示したが、図4の結果から明らかのように、学習された有向非循環グラフには、複数のコライダーが存在している。このこと

<sup>20</sup>表1の結果から、双方向の因果が検出されたものを除いている。

<sup>21</sup>ただし、Inamura *et al.* [14] は、「自社の販売価格」予想に販売価格の実績が影響を与えていると報告しており、ここでの結果とは必ずしも整合的でない。

<sup>22</sup>国内需給についても同様に、「ほぼ均衡」という選択肢を中心に、「需要超過」と「供給超過」についての判断を三択で問うている。

<sup>23</sup>この結果は、興味深くはあるものの、解釈が困難である。今後の研究課題としたい。

は、企業のインフレ予想の形成が合理的予想形成仮説と整合的でないことを示唆している。

### 5.3 主たる学習結果の金融政策に対する含意

5.1 節のランダム・フォレストと 5.2 節のベイジアン・ネットワークの学習結果のうち、以下の四点は、金融政策に対して、とりわけ重要な含意を有している。

結果 1: 「物価全般」予想は、各企業に共通のマクロ変数と密接に関係している。

結果 2: 「物価全般」「自社の販売価格」いずれでみても、GDP ギャップに関連するような実物変数が予想形成に果たす役割の重要度は低い。

結果 3: マクロ変数と企業規模の重要度は、「物価全般」と「自社の販売価格」予想で異なっている。

結果 4: 長期のインフレ予想は、各企業に固有のミクロ変数の影響を受けにくい。

結果 1 の金融政策に対する含意は明快である。すなわち、金融政策がこのマクロ変数に働きかけられるのであれば、金融政策は、「物価全般」予想にも働きかけられる可能性がある。この点、宇野・永沼・原 [1] は、日本銀行が発行する「展望レポート」を用いた自然実験により、中央銀行の情報発信が「物価全般」予想に影響を与えていると主張している。

結果 2 は、マクロのフィリップス曲線において、GDP ギャップにかかる係数が小さいことと整合的である。また、本稿のデータでは検証が困難ながら、近年のフィリップス曲線のフラット化を示唆している可能性もある。インフレ率を制御する役割を担う中央銀行にとって、こうした事実は、きわめて重要な意味がある。

結果 3 は、「物価全般」と「自社の販売価格」とでは、予想形成メカニズムが異なっていることを示唆している。中央銀行がインフレーション・ターゲティング政策を採用する際、多くの場合、そのターゲットは、「物価全般」の先行きである。これを踏まえると、「物価全般」と「自社の販売価格」の予想形成メカニズムの違いは、少なくとも中央銀行にとっては重要な意味がある。もっとも、こうした違いが理論モデルにおいて明示的に扱われることは、これまでのところ必ずしも多くない。今後の研究課題である。

結果 4 も重要な含意を有している。宇野・永沼・原 [1] は、長期のインフレ予想の改定頻度が短期より頻繁であることを報告しているが、ここでの結果とあわせて考えると、長期のインフレ予想のより頻繁な改定は、各企業に共通したマクロ変数によって引き起こさ

れていた可能性が高い。もっとも、現時点では、そのマクロ変数が何を指すのかについて、はっきりしたことは何もいえない。この点も、今後の重要な研究課題である。

## 6 結論

本稿は、短観の個票データという大規模データを用いて、企業のインフレ予想形成行動を「機械」に学習させることを試みた。主たる学習の結果は、次の四点である。第一に、「物価全般」予想は、各企業に共通のマクロ変数と密接に関係している。第二に、「物価全般」「自社の販売価格」いずれの予想でみても、GDPギャップに関連するような実物変数の重要度は低い。第三に、「物価全般」と「自社の販売価格」とでは、予想形成メカニズムが異なっている。第四に、長期のインフレ予想は、各企業に固有のマイクロ変数の影響を受けにくい。

ただし、これらの結果の背後にあるメカニズムについて、「機械」は、何も示唆しない。こうした事実を説明できるような企業の行動原理を明らかにすることは、今後、経済学が果たすべき重要な役割である。

以上

## 参考文献

- [1] 宇野洋輔・永沼早央梨・原尚子 (2017) 「企業のインフレ予想形成に関する新事実：PART I —粘着情報モデル再考—」日本銀行ワーキングペーパー・シリーズ No.17-J-3.
- [2] 岡崎陽介・敦賀智裕 (2015) 「ビッグデータを用いた経済・物価分析について—研究事例のサーベイと景気ウォッチャー調査のテキスト分析の試み—」日本銀行調査論文.
- [3] 杉山将 (2013) 「イラストで学ぶ機械学習：最小二乗法による識別モデル学習を中心に」講談社.
- [4] 西野孝佑・山本弘樹・北原潤・永幡崇 (2016) 「『量的・質的金融緩和』の3年間における予想物価上昇率の変化」日銀レビュー 2016-J-17(「総括的検証」補足ペーパーシリーズ (1)).
- [5] BAJARI, PATRICK, DENIS NEKIPELOV, STEPHEN P. RYAN, AND MIAOYU YANG (2015) “DEMAND ESTIMATION WITH MACHINE LEARNING AND MODEL COMBINATION,” *NBER Working Paper Series* No.20955.
- [6] BHOLAT, DAVID, STEPHEN HANSEN, PEDRO SANTOS AND CHERYL SCHONHARDT-BAILEY (2015) “TEXT MINING FOR CENTRAL BANKS,” *Bank of England Centre for Central Banking Studies Handbook* No.33.
- [7] BISHOP, CHRISTOPHER M. (2006) *Pattern recognition and machine learning*, NEW YORK: SPRINGER.
- [8] BREIMAN, LEO (1996) “BAGGING PREDICTORS,” *Machine Learning* 24(2), PP.123–140.
- [9] BREIMAN, LEO (2001) “RANDOM FOREST,” *Machine Learning* 45(1), PP.5–32.
- [10] CHICKERING, DAVID M. (2002) “OPTIMAL STRUCTURE IDENTIFICATION WITH GREEDY SEARCH,” *Journal of Machine Learning Research* 3, PP.507–554.
- [11] COIBION, OLIVIER AND YURIY GORODNICHENKO (2015) “IS THE PHILLIPS CURVE ALIVE AND WELL AFTER ALL? INFLATION EXPECTATIONS AND THE MISSING DISINFLATION,” *American Economic Journal: Macroeconomics* 7(1), PP.197–232.

- [12] COIBION, OLIVIER, YURIY GORODNICHENKO, AND SATEN KUMAR (2015) “HOW DO FIRMS FORM THEIR EXPECTATIONS? NEW SURVEY EVIDENCE,” *NBER Working Paper Series* No.21092.
- [13] EINAV, LIRAN AND JONATHAN LEVIN (2014) “THE DATA REVOLUTION AND ECONOMIC ANALYSIS,” IN *Innovation Policy and the Economy*, UNIVERSITY OF CHICAGO PRESS.
- [14] INAMURA, KOUKI, KAZUNORI HIYAMA, AND KYOSUKE SHIOTANI (2017) “INFLATION OUTLOOK AND BUSINESS CONDITIONS OF FIRMS: EVIDENCE FROM THE TANKAN SURVEY,” *IFC Bulletin* 43, SESSION 4 B - MACROECONOMIC VULNERABILITIES.
- [15] JACOMY, MATHIEU, SEBASTIEN HEYMANN, TOMMASO VENTURINI, AND MATHIEU BASTIAN (2012) “FORCEATLAS2, A CONTINUOUS GRAPH LAYOUT ALGORITHM FOR HANDY NETWORK VISUALIZATION,” IN [HTTP://WWW.MEDIALAB.SCIENCES-PO.FR/PUBLICATIONS/](http://www.medialab.sciences-po.fr/publications/)
- [16] KUMAR, SATEN, HASSAN AFROUZI, OLIVIER COIBION, AND YURIY GORODNICHENKO (2015) “INFLATION TARGETING DOES NOT ANCHOR INFLATION EXPECTATIONS: EVIDENCE FROM FIRMS IN NEW ZEALAND,” *Brookings Papers on Economic Activity* 2015(2), PP.151–225.
- [17] HANSEN, STEPHEN, MICHAEL MCMAHON, AND ANDREA PRAT (2016) “TRANSPARENCY AND DELIBERATION WITHIN THE FOMC: A COMPUTATIONAL LINGUISTICS APPROACH,” Mimeo.
- [18] MANKIW, N. GREGORY AND RICARDO REIS (2002) “STICKY PRICE VERSUS STICKY INFORMATION: A PROPOSAL TO REPLACE THE NEW KEYNESIAN PHILLIPS CURVE,” *Quarterly Journal of Economics* 117(4), PP.1295–1328.
- [19] MANKIW, N. GREGORY, RICARDO REIS, AND JUSTIN WOLFERS (2004) “DISAGREEMENT ABOUT INFLATION EXPECTATION,” *NBER Macroeconomic Annual* 2003 18, PP.209–248.
- [20] NEWMAN, MARK E. J. AND MICHELLE GIRVAN (2004) “FINDING AND EVALUATING COMMUNITY STRUCTURE IN NETWORKS,” *Physical Review* E69, 026113.

- [21] PEARL, JUDEA (1988) *Probabilistic reasoning and intelligent systems: Networks of plausible inference*, MORGAN KAUFMANN PUBLISHERS INC.
- [22] PEARL, JUDEA (2009) *Causality: Models, reasoning, and inference*, 2ND EDITION, CAMBRIDGE UNIVERSITY PRESS.
- [23] SIMS, CHRISTOPHER A. (2003) “IMPLICATIONS OF RATIONAL INATTENTION,” *Journal of Monetary Economics* 50(3), PP.665–690.
- [24] SPIEGLER, RAN (2016) “CAN AGENTS WITH CAUSAL MISPERCEPTIONS BE SYSTEMATICALLY FOOLED?,” Mimeo.
- [25] SPIRITES, PETER, CLARK GLYMOUR, AND RICHARD SCHEINES (2001) *Causation, prediction, and search*, 2ND EDITION, MIT PRESS.
- [26] VARIAN, HAL R. (2014) “BIG DATA: NEW TRICKS FOR ECONOMETRICS,” *Journal of Economic Perspectives* 28(2), PP.3–28.

## A Rのコード

上段がランダム・フォレストの変数重要度、下段がPCアルゴリズムによるベイジアン・ネットワークの学習に用いたRのコードである。

```
library(randomForestSRC)
library(ggRandomForests)
NumTree <- 1000
res_rfsrc <- rfsrc(
  ie1 ~ time + var1 + var2 + var3 + var4 + var5 + var6 + var7 + var8 + var9 + var10
  , data = data,
  ntree = NumTree,
  mtry = floor(sqrt(11)),
  na.action = "na.impute",
  importance = "permute")
res_vimp <- gg_vimp(res_rfsrc)
plot(res_vimp)
```

```
library(huge)
library(pcalg)
cov <- cov(huge.npn(data))
suffStat <- list(C = cov2cor(cov), n = N)
V = rownames(cov)
FixEdge <- matrix(rep(FALSE, length(V)^2), nrow = length(V))
pc.fit <- pc(suffStat, indepTest = gaussCltest, labels = V,
  skel.method = "stable",
  alpha = 0.05,
  solve.confl = TRUE, conservative = TRUE,
  res_fixedEdges = FixEdge)
```

以上

(表 1)


## インフレ予想と直接的に結びついている変数

<原因>		<結果>	
物価全般			
1年後予想	国内需給(最近)、雇用過不足(最近)、「自社販売価格」1年後、同3年後		
3年後予想	「物価全般」1年後、同5年後、「自社販売価格」3年後		
5年後予想	業況(先行き)、「物価全般」3年後、「自社販売価格」1年後、同5年後		
自社の販売価格			
1年後予想	雇用過不足(最近、先行き)、資金繰り、「物価全般」1年後、同5年後		
3年後予想	販売価格(先行き)、「物価全般」1年後、同3年後、「自社販売価格」1年後		
5年後予想	「物価全般」1年後、同5年後、「自社販売価格」1年後、同3年後		
<結果>		<原因>	
物価全般			
1年後予想	資金繰り、仕入価格(最近)、「物価全般」3年後、「自社販売価格」1年後、同3年後、同5年後		
3年後予想	「物価全般」5年後、「自社販売価格」3年後		
5年後予想	業況(先行き)、販売価格(最近)、「物価全般」3年後、「自社販売価格」1年後、同5年後		
自社の販売価格			
1年後予想	資金繰り、販売価格(先行き)、「物価全般」1年後、同5年後、「自社販売価格」3年後、同5年後		
3年後予想	企業規模、販売価格(先行き)、「物価全般」1年後、同3年後、「自社販売価格」5年後		
5年後予想	「物価全般」5年後		



(図 1)

有向非循環グラフの例



(図 2)

### ランダム・フォレストの変数重要度：物価全般



(図 3)

### ランダム・フォレストの変数重要度：自社の販売価格



(図 4)

ベイジアン・ネットワークの学習結果

