

# IMES DISCUSSION PAPER SERIES

## 日本銀行による景気判断のトーン分析

かざとまさゆき くろさきてつお ごしまけいいち  
風戸正行・黒崎哲夫・五島圭一

Discussion Paper No. 2019-J-16

# IMES

INSTITUTE FOR MONETARY AND ECONOMIC STUDIES

BANK OF JAPAN

日本銀行金融研究所

〒103-8660 東京都中央区日本橋本石町 2-1-1

日本銀行金融研究所が刊行している論文等はホームページからダウンロードできます。

<https://www.imes.boj.or.jp>

無断での転載・複製はご遠慮下さい。

備考：日本銀行金融研究所ディスカッション・ペーパー・シリーズは、金融研究所スタッフおよび外部研究者による研究成果をとりまとめたもので、学界、研究機関等、関連する方々から幅広くコメントを頂戴することを意図している。ただし、ディスカッション・ペーパーの内容や意見は、執筆者個人に属し、日本銀行あるいは金融研究所の公式見解を示すものではない。

## 日本銀行による景気判断のトーン分析

かざとまさゆき    くろさきてつお    ごしまけいいち  
風戸正行\*・黒崎哲夫\*\*・五島圭一\*\*\*

### 要 旨

本研究は、2008～17 年を対象に、日本銀行による景気判断のトーンと金融市場における金融政策予想の関係を分析している。深層学習モデルに基づくテキスト分析の手法を用いて、金融政策決定会合後の総裁記者会見における景気判断トーンを定量化したうえで、それを既往情報による成分と付加情報による成分（トーン・ショック）に分解している。オーバーナイト・インデックス・スワップレートのボラティリティを、同ショックを含む諸変数に回帰したところ、正のトーン・ショックが生じると、黒田総裁就任以降においては、同ボラティリティが低下することが確認された。

キーワード：中央銀行コミュニケーション、金融政策、総裁定例記者会見、トーン・ショック、テキスト分析、深層学習モデル

JEL classification: C82、D83、E44、E58

\* 日本銀行金融研究所企画役補佐（現金融機構局企画役補佐、E-mail: masayuki.kazato@boj.or.jp）

\*\* 日本銀行金融研究所企画役（現金融機構局企画役、E-mail: tetsuo.kurosaki@boj.or.jp）

\*\*\* 早稲田大学・日本銀行金融研究所（E-mail: keiichi.goshima@aoni.waseda.jp）

本稿の作成に当たっては、竹田陽介教授（上智大学）、宮川大介准教授（一橋大学）、大坪陽一講師（マンチェスター大学）、アミン・タラチ教授（リモージュ大学）、ならびに金融研究所スタッフ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、本稿に示されている意見は、筆者たち個人に属し、日本銀行の公式見解を示すものではない。また、ありうべき誤りはすべて筆者たち個人に属する。

## 1. はじめに

中央銀行は、民間経済主体に対して、金融政策の目的や手段のほか、経済や金融政策の見通しに関する情報を発信する。こうした情報発信は、中央銀行コミュニケーションにおいて重要な位置を占めており、人々の物価予想や金融市場価格に対するさまざまな影響を通じて、金融政策の実効性の向上に貢献し得る (Blinder [1998]、Blinder *et al.* [2008])。人々の期待の制御を金融政策の本質とする見方もある (Woodford [2001])。

これまで、中央銀行コミュニケーションの重要性は、さまざまな政策手段の文脈のなかで指摘されてきた。1990年代には、多くの中央銀行で導入された物価上昇率目標の効果との関係で議論された (Bernanke and Mishkin [1997]、Svensson [1997])。こうしたなか、1999年、日本銀行は、ゼロ金利政策とともに、デフレ懸念が払拭されるまで同政策にコミットする政策(コミットメント政策)を導入した。コミットメント政策は、人々の期待に働きかけることによって、名目金利の実効下限制約を超えて金融緩和効果を生み出すことを企図しており、その有効性が指摘されてきた (翁・白塚・藤木 [2000])。今日フォワード・ガイダンスとして広く知られる同様の政策は、今般の金融危機を経て名目金利の実効下限制約に直面した多くの中央銀行で導入されている。フォワード・ガイダンスの政策効果については、Levin *et al.* [2010]をはじめ、盛んに研究されている。さらに近年、中央銀行は、伝統的な金融政策に加え、国債を中心とする大規模な資産買入やマイナス金利などの非伝統的金融政策を導入しているが、こうした新しい政策の意図を人々に正しく浸透させるためにも、コミュニケーションは重要な役割を担うと考えられる (鎌田 [2014])。

中央銀行は民間経済主体に対してさまざまな情報提供を行っているが、広範囲への影響力をもつ代表的な情報提供手段の1つが、金融政策決定会合後の総裁記者会見である。多くの主要先進国の中央銀行では、金融政策の決定内容にかかる声明文の公表後、記者会見を開催し、総裁自らが政策決定内容に対して、決定の背景となった金融経済環境の現状認識や先行き見通しなどと合わせて、説明を行っている。また通常、決定内容の意図をより分かりやすく伝達するために、記者との間で質疑応答も行われる。Ehrmann and Fratzscher [2009]は、欧州中央銀行 (European Central Bank: ECB) を対象に、記者会見の内容が、声明文そのものよりも金融市場に大きな影響を及ぼすとの分析結果を得ている。

中央銀行による情報発信が金融市場に及ぼす影響については、かつては情報発信前後における各種金融変数の反応を観察することが標準的な検証方法で

あった（中島・服部 [2010]）。しかしながら、情報処理技術の向上を受けて目覚ましく発展している機械学習モデルなどを用いたテキスト分析を、中央銀行コミュニケーションの分野へ応用する研究が盛んになっている。すなわち、これらの研究においては、中央銀行が公表する文書などのテキストを機械学習モデルなどで処理し、テキスト内容を数値情報として評価することで、金融変数との関係をより定量的に計測している。

テキスト分析による中央銀行コミュニケーションの研究は、米欧の中央銀行を対象としたものが先駆的である。Hansen and McMahon [2016]や Jegadeesh and Wu [2017]は、潜在的ディリクレ配分法と呼ばれるテキストのトピック分類のための機械学習モデルを用いて、米国連邦公開市場委員会（Federal Open Market Committee: FOMC）の議事録をトピック分類したうえで極性辞書によってテキストを数値評価し、金融市場への影響について分析している。ECB の公表文書を対象とした分析には Bulíř, Čihák, and Šmídková [2013]や Milea *et al.* [2012]など、また、カナダ銀行の公表文書を対象とした分析には、Hendry and Madeley [2010]や Ehrmann and Talmi [2017]などがある。イングランド銀行スタッフのレビュー論文である Bholat *et al.* [2015]は、中央銀行におけるテキスト分析の活用について、先行研究を紹介しつつ包括的に議論している。本邦においても、Kawamura *et al.* [2019]が極性辞書を用いて、山本・松尾 [2016] が深層学習モデルを用いて、それぞれ日本銀行の公表文書を対象としたテキスト分析を行っている<sup>1</sup>。

本研究では、こうした中央銀行コミュニケーションに関する研究の潮流を踏まえ、日本銀行を対象として、金融政策決定会合後の総裁定例記者会見における景気判断が金融市場における金融政策予想に及ぼした影響の有無や、その程度を分析する。

本研究の具体的な分析方法は、次のとおりである。最初に、金融政策決定会合後の総裁定例記者会見における政策説明に含まれる景気の評価に関する情報を、深層学習モデルを用いて数値化する。本研究では、こうした数値を日本銀行のトーンと呼ぶ。次に、Hubert and Labondance [2017]の手法を参考に、日本銀行のトーンに含まれる、既往情報から予想できない付加情報による成分であるトーン・ショックを抽出する。そして、日本銀行のトーン・ショックが、金融政策予想の代理変数であるオーバーナイト・インデックス・スワップ（Overnight Index Swap : OIS）レートを説明するか否かを検証する。

既存研究と比べた本研究の特徴は 2 点ある。1 点目は、テキストのトーンの定量化に当たって、機械学習モデル、特に深層学習モデルを用いることである。

---

<sup>1</sup> 極性辞書については 2 節（1）を、深層学習については補論を参照。

2 点目は、先行研究の手法を拡張して、広範囲の金融経済変数を既往情報として考慮することで、トーン・ショックをより精緻に抽出していることである。

本稿の構成は次のとおりである。2 節では、テキストのトーンを定量化する手段のほか、トーンからトーン・ショックを抽出するための手法を説明する。3 節では、分析に用いるデータについて述べる。4 節では、実証分析で得られた結果を示す。5 節では、結論および今後の課題を述べる。

## 2. 分析手法

本研究では、日本銀行による景気判断のトーンを、Zhang, Zhao, and Lecun [2015]によって提案された深層学習モデルを用いて定量化する。その後、Hubert and Labondance [2017]によって提案された手法を用いて、日本銀行のトーンに含まれる、既往情報から予想できない付加情報による成分であるトーン・ショックを抽出する。本節では、これらの手法の詳細を説明する。

### (1) テキストの定量化手法

金融経済分野のテキスト分析においては、結果の解釈のしやすさや導入の容易さなどの理由から、極性辞書を用いた手法が標準的である。極性辞書とは、事前に用意された特定の単語について、肯定的な意味合いがあるか、否定的な意味合いがあるかを表した極性値とともに収録した単語リストのことであり、分析したいテキストに含まれる単語の極性値を累計することで、テキストのトーンを数値として評価することが可能となる。もっとも、極性辞書には、例えば「業績が良くない」といった否定的なテキストに対しても、「良」という肯定的な極性値をもつ単語が含まれているために肯定的に評価してしまうなど、文脈を正しく捉えられないという欠点が指摘されている。加えて、一般的に入手可能な日本語の極性辞書をみると、金融経済分野に特化し、かつ多数の先行研究においてその有効性が確認されている極性辞書は、筆者らが知る限り、これまでのところ存在していない。

こうした極性辞書の問題点を踏まえ、本研究では、テキストの数値評価にあたって、機械学習モデル、特に深層学習モデルを用いることとした。具体的には、本研究では、Zhang, Zhao, and LeCun [2015]により提案された深層学習モデルの 1 つである、文字単位の畳み込みニューラル・ネットワーク・モデルを用いた<sup>2</sup>。深層学習モデルでは、テキストにおける単語の出現頻度のみでなく、単

---

<sup>2</sup> モデルの概要は補論を参照。

語の並び順や出現位置、単語間の出現パターンの類似度（共起関係）などといった文脈も含めてテキストの構造を解釈することが可能である。このため、極性辞書と比べると、人間がテキストを読んだ際の実感に合うという点も含め、より適切にテキストのトーンを定量化できると期待される<sup>3</sup>。本邦においても、山本・松尾 [2016]、五島・高橋 [2016] や五島・高橋・山田 [2019] などが深層学習モデルを用いてニュース記事や経済レポートのテキストの数値評価を行い、それらの数値が金融経済変数の変動を精度よく説明することを示している。

金融経済分野のテキスト分析に用いられている機械学習モデルは、教師なし学習モデルと教師あり学習モデルに分類される<sup>4</sup>。教師なし学習モデルとは、入力のみからパターンを学習するモデルである。一方、教師あり学習モデルとは、入力だけでなく、入力と出力がペアとなったデータ（教師データ）に基づいて学習するモデルである。教師なし学習モデルと比べると、教師あり学習モデルは入出力の関係をより高い精度で推定（学習）できるため、未知の入力に対してより正確に出力を予測することが可能となる。本研究でも、入力（テキスト）からより適切な出力（景気の評価を表す数値）を得ることを目的に、教師あり学習モデルを採用する。

本研究では、教師データとして、山本・松尾 [2016] や五島・高橋・山田 [2019] と同様、景気ウォッチャー調査を用いる。景気ウォッチャー調査とは、「地域の景気に関連の深い動きを観察できる立場にある人々の協力を得て、地域ごとの景気動向を的確かつ迅速に把握し、景気動向判断の基礎資料とすること」を目的に、内閣府が毎月公表している調査である<sup>5</sup>。景気ウォッチャー調査の結果は、5段階の景気の現状評価と先行き評価（以下、現状評価と先行き評価）が、その主だった判断理由のテキスト（景気判断理由集）とペアになって公表される<sup>6</sup>。

---

<sup>3</sup> Tobback, Stefano, and Martens [2017]は、エキスパート・ジャッジメントによるテキスト分析は、属人的な要素が強く再現性が乏しいことなどを指摘したうえで、客観性が高い機械学習モデルによるテキスト分析を推奨している。

<sup>4</sup> 機械学習モデル一般には、教師なし学習モデルと教師あり学習モデルのほかに、囲碁やチェスなどゲームにおける応用が進む強化学習モデルが存在する。強化学習モデルは、出力結果に応じて一定の報酬が与えられるような環境（ゲームのルールに相当）において、その報酬を最大化するようパラメータを最適化する学習モデルである。

<sup>5</sup> 景気ウォッチャー調査の概要は、内閣府のウェブサイト（[https://www5.cao.go.jp/keizai3/watcher/watcher\\_menu.html](https://www5.cao.go.jp/keizai3/watcher/watcher_menu.html)）を参照。

<sup>6</sup> 現状評価は、「3ヵ月前と比較し現状の景気が上向きか下向きか」という判断基準のもとでの回答であり、先行き評価は、「当月と比較し今後2～3ヵ月先の将来の景気が上向きか下向きか」という判断基準のもとでの回答である。また、5段階の評価は、現状評価では「良くなっている」・「やや良くなっている」・「変わらない」・「やや悪くなっている」・「悪くなっている」に、先行き評価では「良くなる」・「やや良くなる」・「変わらない」・「やや悪くなる」・「悪くなる」にそれぞれ対応する。本研究ではそれぞれに 4、3、2、1、0

表 1 は、景気判断理由集の一部を抜粋したものである。本研究では、2011 年 1 月から 2017 年 9 月までを対象期間とする。表 2 は、当該期間における、5 段階の評価に対応する景気判断理由のテキスト数の内訳を示したものである。

**表 1 景気判断理由集（一部抜粋）**

| 現状評価      | 判断理由                                   |
|-----------|----------------------------------------|
| 良くなっている   | 派遣先において、派遣スタッフの直接雇用への転換事例が増えている。       |
| やや良くなっている | 資金ニーズがやや増えてきている。                       |
| 変わらない     | 年始は好調に推移したが、月の後半にかけて鈍化してきている。          |
| やや悪くなっている | 米国の新大統領就任による影響で、やや悪くなっている。             |
| 悪くなっている   | 当社特有の繁忙期が過ぎたため、受注量が減少している。             |
| 先行き評価     | 判断理由                                   |
| 良くなる      | 総決算セールと引っ越しシーズンが重なるため、良くなる。            |
| やや良くなる    | 3 月発売の新機種の予約が好調なので期待したい。               |
| 変わらない     | 既存顧客からの新規案件はなく、今のところ新年度以降も良くなる気配を感じない。 |
| やや悪くなる    | 海外の政治的な情勢が安定してくれば、景気もやや上向いてくるのではないかと。  |
| 悪くなる      | 米国の新大統領就任による影響で悪くなる。                   |

資料：『景気ウォッチャー調査』（内閣府）より作成。

の数値を割り当てる。



表 2 景気判断理由のテキスト数の内訳

| 現状評価      | テキスト数   | 先行き評価  | テキスト数   |
|-----------|---------|--------|---------|
| 良くなっている   | 2,077   | 良くなる   | 2,248   |
| やや良くなっている | 22,882  | やや良くなる | 26,877  |
| 変わらない     | 49,017  | 変わらない  | 57,421  |
| やや悪くなっている | 23,345  | やや悪くなる | 22,671  |
| 悪くなっている   | 6,238   | 悪くなる   | 6,014   |
| 総計        | 103,559 |        | 115,231 |

資料：『景気ウォッチャー調査』（内閣府）より作成。

日本銀行による景気判断のトーンを定量化する手法の詳細は以下のとおりである。はじめに、景気ウォッチャー調査の景気判断理由集を教師データとして、入力テキストに対して景気の評価を表す数値を出力する、Zhang, Zhao, and LeCun [2015]の深層学習モデルを学習する。ここで、教師データが2種類（現状評価と先行き評価）あるため、それぞれの教師データに対応して2種類のモデルが学習される。次に、入力テキストが $n$ 個の文（句点から次の句点まで）から構成されているとき、モデルに個々の文 $i$  ( $1 \leq i \leq n$ )を入力することで、現状および先行きの評価を表す数値を推定する。この数値を $Score_{i,k}$ と表す<sup>7</sup>。 $k$ は、現状評価 ( $k = nowcast$ ) または先行き評価 ( $k = forecast$ ) を表すインデックスである。このとき、 $Score_{i,k}$ を入力テキストの各文 $i$ について集計することで、入力テキストに含まれる景気の評価を定量化することができる。

ここで、入力テキストの各文 $i$ が、現状評価に関して記述しているのか、先行き評価に関して記述しているのか、明確ではない点が問題となる。例えば、現状（先行き）について記述している文に対して、先行き（現状）の数値を出力することに特段の意味はないと考えられる。このような問題意識のもと、各文の数値を集計するにあたっては、五島・高橋・山田 [2019] を参考に、単純平均ではなく、入力テキストの各文 $i$ が現状あるいは先行きのどちらのトピックに近いかを表す確率 $W_i$  ( $0 \leq W_i \leq 1$ ) をウェイトとして各文の $Score_{i,k}$ を重み付けし、加重平均をとることとした。ここで、確率 $W_i$ については、以下のように推定している。はじめに、景気ウォッチャー調査の景気判断理由集のうち、現状評価の判断理由集に掲載されているテキストを0、先行き評価の判断理由集

<sup>7</sup>  $Score_{i,k}$ は、0から4の値を取ることが期待される。もっとも、本研究で用いた深層学習モデルは、入力テキストに対し、景気ウォッチャー調査の5段階のスコアを連続値として出力するため、 $Score_{i,k}$ は4より大きい値や0より小さい値を取りうる。ただし、本研究では、そうした値の $Score_{i,k}$ は推定されなかった。

に掲載されているテキストを 1 とする教師データを用いて、Zhang, Zhao, and LeCun [2015]の深層学習モデルに基づいてトピック分類モデルを推定する。このトピック分類モデルに入力テキストの各文  $i$  を入力することで  $W_i$  を推定する。 $W_i$  は、現状評価のトピックに近いほど 0、先行き評価のトピックに近いほど 1 に近い値をとる。

以上をまとめると、テキストのトーン  $Tone_k$  は、以下の式で与えられる。

$$Tone_k = \sum_{i=1}^n Score_{i,k} \times W_{i,k} / \sum_{i=1}^n W_{i,k},$$

$$W_{i,k} = \begin{cases} 1 - W_i, & k = \text{nowcast} \\ W_i & , k = \text{forecast} \end{cases} . \quad (1)$$

なお一般に、深層学習モデルの学習では、適当な初期値から出発して最適なパラメータの探索が行われるが、学習結果は初期値に依存する。このため、推定精度の向上を目的として、異なる初期値のもとで独立に複数回モデルを学習し、1 つの入力に対する各モデルの出力の平均値を、出力として採用する方法がある（アンサンブル学習）。本研究においても、現状評価および先行き評価を推定するモデル、および現状・先行きに関するトピック分類モデルをそれぞれ 100 回ずつ学習・推定し、各モデルの出力の平均値を  $Score_{i,k}$  および  $W_i$  としている。

## （２） 日本銀行のトーン・ショックの抽出手法

本節では、Hubert and Labondance [2017]が提案した手法を応用し、既往情報から予想できない付加情報による成分であるトーン・ショックを、日本銀行のトーンから抽出する方法について説明する。

はじめに、本節（１）で解説した深層学習モデルを用いて定量化した日本銀行のトーンを  $\mathcal{E}_{BOJ,MPM}$  で表す。ここで、 $MPM$  は、各回の金融政策決定会合（Monetary Policy Meeting）を表す。このとき、前回の金融政策決定会合における景気判断からのトーンの変化  $\Delta \mathcal{E}_{BOJ,MPM}$  は、既往情報の変化に起因する成分  $f(\Delta X_{MPM})$ 、およびトーン・ショックに起因する成分  $\xi_{BOJ,MPM}$  を用いて、以下のように表すことができる。

$$\Delta \mathcal{E}_{BOJ,MPM} = f(\Delta X_{MPM}) + \xi_{BOJ,MPM} . \quad (2)$$

日本銀行の物価見通しと民間経済主体の物価予想を既往情報として追加的に考慮し、さらに Romer and Romer [2004]による金融政策ショックを仮定することで、(2)式は、具体的に以下のように書き下せる。

$$\begin{aligned}\Delta E_{BOJ,MPM} = & \beta_0 + \beta_1 \Delta \Omega_{MPM} + \beta_2 MP_{MPM} + \beta_3 \Delta \psi_{MPM} \\ & + \beta_4 \Delta Y_{MPM} + \beta_5 \Delta Z_{MPM} + \xi_{BOJ,MPM} .\end{aligned}\quad (3)$$

ここで、 $\Omega_{MPM}$ は日本銀行による物価見通し、 $MP_{MPM}$ は金融政策ショック（潜在金利の変化）、 $\psi_{MPM}$ は民間経済主体の物価予想、 $Y_{MPM}$ 、 $Z_{MPM}$ はそれぞれ金融政策決定会合日までに公表されている代表的な経済変数および金融変数を表す。すなわち、日本銀行のトーンにおけるトーン・ショック $\xi_{BOJ,MPM}$ は、被説明変数をトーンの変化、説明変数を金融経済変数などの既往情報の変化とした重回帰分析の残差として抽出される。

もともと、Hubert and Labondance [2017]では、トーン・ショックの抽出に際して一部の代表的な金融経済変数のみを既往情報として考慮しているため、トーンに含まれる既往情報が十分に除外されず、トーン・ショックは過大評価されている可能性がある。そこで本研究では、トーンに含まれる既往情報を可能な限り除外し、より適切なトーン・ショックを抽出するため、多数の金融経済変数の主成分を既往情報として用いた。

本研究で考慮した金融経済変数は、2015年12月まで公表されていた金融経済月報における国内主要経済指標のうち32系列の経済変数 $Y_{MPM}$ と、日本銀行金融経済統計月報に記載されている金融関連指標のうち21系列の金融変数 $Z_{MPM}$ の合計53系列である<sup>8</sup>。これらの金融経済変数の階差系列から抽出した主成分 $\Delta X_{MPM}^{PC}$ を考慮すると、(3)式は以下のように変形できる。

$$\begin{aligned}\Delta E_{BOJ,MPM} = & \beta_0 + \beta_1 \Delta \Omega_{MPM} + \beta_2 MP_{MPM} + \beta_3 \Delta \psi_{MPM} \\ & + \beta_4 \Delta X_{MPM}^{PC} + \xi_{BOJ,MPM} .\end{aligned}\quad (4)$$

また、景気ウォッチャー調査を教師データとする本研究のトーン定量化手法では、現状評価と先行き評価のトーンをそれぞれ定量化できるため、対応するトーン・ショックも(4)式を通じてそれぞれ推定できる。先行き評価のトーンに含まれると考えられる情報を踏まえると、先行き評価のトーン・ショックについては、日本銀行の物価見通し、金融政策ショックや民間の物価予想といったフワード・ルッキングな情報も既往情報として含めた(4)式で抽出することが妥当である一方、現状評価のトーン・ショックについては、公表済みの経済・金融変数のみを情報として（すなわち、 $\beta_1 = \beta_2 = \beta_3 = 0$ として）抽出することが妥当と考えられる。このため、現状評価のトーン $E_{BOJ,MPM}^{Nowcast}$ と先行き評価のトーン $E_{BOJ,MPM}^{Forecast}$ からそれぞれのトーン・ショック $\xi_{BOJ,MPM}^{Nowcast}$ 、 $\xi_{BOJ,MPM}^{Forecast}$ を抽出するにあ

<sup>8</sup> 具体的な変数の一覧や単位などについては、3節（2）を参照。

たつては、それぞれ下記の式を用いた<sup>9</sup>。

$$\begin{aligned}\Delta \varepsilon_{BOJ,MPM}^{Nowcast} &= \beta_0 + \beta_4 \Delta X_{MPM}^{PC} + \xi_{BOJ,MPM}^{Nowcast}, \\ \Delta \varepsilon_{BOJ,MPM}^{Forecast} &= \beta_0 + \beta_1 \Delta \Omega_{MPM} + \beta_2 MP_{MPM} + \beta_3 \Delta \psi_{MPM} + \beta_4 \Delta X_{MPM}^{PC} \\ &\quad + \xi_{BOJ,MPM}^{Forecast}.\end{aligned}\tag{5}$$

さらに、(5)式の推定においては、金融政策決定会合の性質の違いを考慮するため、2種類の異なるダミー変数を導入した。具体的には、①あらかじめ開催日程が決まっていない臨時の金融政策決定会合による影響と、②年間開催回数が14回から8回となり、開催期間の間隔が変化した2016年以降の金融政策決定会合による影響を考慮した。

### (3) 日本銀行のトーン・ショックがOIS市場に与えた影響

日本銀行によるトーン・ショックは、金融市場に対して影響を及ぼすと考えられる。特に、無担保コールレート（オーバーナイト物）に対する市場参加者の予想であるOISレートは、先行きの日本銀行の金融政策に対する市場参加者の見方が反映されていると考えられるため、日本銀行による先行き評価のトーン・ショックによる影響を受けやすいと考えられる。

そこで本研究では、EGARCH (exponential generalized autoregressive conditional heteroscedasticity) 型のボラティリティ変動モデル (Nelson [1991]) を推定し、日本銀行における先行き評価のトーン・ショックが、満期1～12カ月のOISレートのボラティリティに与えた影響について分析を行った。モデルの推定に用いるデータの頻度は日次とし、2008年4月9日～2017年9月21日までの期間を対象とした。推定を行うモデルは下記のとおりである。

$$\begin{aligned}\Delta OIS_{t,m} &= C_1 + C_2 \Delta r_{t-1} + C_3 \xi_{BOJ,t}^{Forecast} + C_4 MPM_{dummy} \\ &\quad + \varepsilon_{t,m}, \quad \varepsilon_{t,m} \sim N(0, \sigma_{t,m}^2), \\ \log \sigma_{t,m}^2 &= C_5 + C_6 \frac{|\varepsilon_{t-1,m}|}{|\sigma_{t-1,m}|} + C_7 \frac{\varepsilon_{t-1,m}}{|\sigma_{t-1,m}|} + C_8 \log \sigma_{t-1,m}^2 \\ &\quad + C_9 \log(NVIX_{t-1}^2/250) + C_{10} \xi_{BOJ,t}^{Forecast} \\ &\quad + C_{11} MPM_{dummy}.\end{aligned}\tag{6}$$

<sup>9</sup> 日本銀行のトーンに対する金融経済変数の影響度が時期により変化する可能性があるため、回帰式をローリング推定することも一案である。もっとも、分析対象となるサンプル数が少ない（白川体制期で77サンプル、黒田体制期で53サンプル）ことを考慮して、本研究では、(5)式のように、各体制期における日本銀行のトーンに対する平均的な金融経済変数の影響を分析することとした。

ここで、 $t$ は日次のインデックスを表し、 $OIS_{t,m}$ は満期 $m$ カ月の OIS レートを表す ( $m = 1, \dots, 12$ )。OIS レートの変化およびボラティリティの説明変数には、日本銀行における先行き評価のトーン・ショックのほか、金融政策決定会合後に総裁定例記者会見が開催された日 ( $t = MPM$ ) を示すダミー変数  $MPM_{dummy}$  を考慮した。ここで  $\xi_{BOJ,t}^{Forecast}$  は、総裁定例記者会見が開催された日にトーン・ショックの値  $\xi_{BOJ,MPM}^{Forecast}$ 、それ以外の日に 0 をとる。また、総裁定例記者会見が開催された日に共通して発生するボラティリティの変動をダミー変数  $MPM_{dummy}$  でコントロールする。このほか、OIS レートの変化の説明変数として無担保コールレート（オーバーナイト物） $r_{t-1}$  を、ボラティリティの説明変数として日経平均ボラティリティ・インデックス  $NVIX_{t-1}$  を、それぞれ考慮した。

### 3. データ

本節では、分析で用いた日本銀行の景気判断のテキストと、トーン・ショック抽出に用いた金融経済変数について説明する。

#### (1) 日本銀行の景気判断のテキスト：総裁定例記者会見の冒頭

日本銀行による景気判断のテキストとして、金融政策決定会合の終了後に速やかに公表される声明文、あるいは総裁定例記者会見における冒頭（質疑応答に入る前のテキスト）が分析対象となりうる。金融市場へ及ぼす影響という観点では、Ehrmann and Fratzscher [2009]は、声明文以上に記者会見の内容が重要であることを指摘している。このため、本研究では、総裁定例記者会見の冒頭を分析対象とした。

分析対象とする総裁定例記者会見の期間は、2008 年 4 月から 2017 年 9 月まで（合計 131 回分）とした。テキストは、日本銀行のウェブサイトに掲載されている総裁定例記者会見要旨から、冒頭を抽出した。本研究では、1 文ごとにテキストのトーンを推定するため、複数の文から構成されている記者会見については、句点ごとの文単位でテキスト処理を行った。

#### (2) 金融経済データ

トーン・ショックの抽出に用いた金融経済変数は、主成分の抽出に用いた変数と、その他の変数に大別される。主成分の抽出に用いた変数については、2015 年 12 月まで日本銀行が公表していた「金融経済月報」の国内主要経済指標に掲載されていた経済変数と、日本銀行金融経済統計月報に記載されている金融変

数を参考にした。経済変数および金融変数の一覧を表3および表4に示している。その他の変数は、日本銀行の物価見通し、金融政策ショックや民間の物価予想を含んでいる。表5にその詳細を示している。

**表3 主成分の抽出に用いた経済変数の一覧**

| 変数名称                        | 単位           | 出所               |
|-----------------------------|--------------|------------------|
| 消費水準指数（2人以上の世帯、総合）          | 季節調整済み前期比    | 『金融経済統計月報』（日本銀行） |
| 小売業販売額（うち百貨店）               | 季節調整済み前期比    | 『金融経済統計月報』（日本銀行） |
| 小売業販売額（うちスーパー）              | 季節調整済み前期比    | 『金融経済統計月報』（日本銀行） |
| 家電販売額                       | 季節調整済み前期比    | 『金融経済統計月報』（日本銀行） |
| 乗用車新車登録台数（軽乗用車を除くベース）       | 前年比          | 『金融経済統計月報』（日本銀行） |
| 旅行取扱額                       | 前年比          | 『金融経済統計月報』（日本銀行） |
| 新設住宅着工                      | 季節調整済み年率・前期比 | 『金融経済統計月報』（日本銀行） |
| 機械受注額（民需＜船舶・電力を除く＞）         | 季節調整済み前期比    | 『金融経済統計月報』（日本銀行） |
| 機械受注額（非製造業＜船舶・電力を除く＞）       | 季節調整済み前期比    | 『金融経済統計月報』（日本銀行） |
| 機械受注額（製造業）                  | 季節調整済み前期比    | 『金融経済統計月報』（日本銀行） |
| 建築物着工（民間のうち非居住用）（床面積）       | 季節調整済み前期比    | 『金融経済統計月報』（日本銀行） |
| 建築物着工（民間のうち非居住用）（床面積＜鉱工業＞）  | 季節調整済み前期比    | 『金融経済統計月報』（日本銀行） |
| 建築物着工（民間のうち非居住用）（床面積＜非製造業＞） | 季節調整済み前期比    | 『金融経済統計月報』（日本銀行） |
| 公共工事請負金額                    | 前年比          | 『金融経済統計月報』（日本銀行） |
| 実質輸出                        | 季節調整済み前期比    | 『金融経済統計月報』（日本銀行） |
| 実質輸入                        | 季節調整済み前期比    | 『金融経済統計月報』（日本銀行） |
| 鉱工業指数（生産＜鉱工業＞）              | 季節調整済み前期比    | 『金融経済統計月報』（日本銀行） |
| 鉱工業指数（生産者出荷＜鉱工業＞）           | 季節調整済み前期比    | 『金融経済統計月報』（日本銀行） |
| 鉱工業指数（生産者在庫＜鉱工業＞）           | 季節調整済み前期比    | 『金融経済統計月報』（日本銀行） |

|                             |           |                      |
|-----------------------------|-----------|----------------------|
| 鉱工業指数（生産者在庫率＜鉱工業＞）          | 季節調整済み前期比 | 『金融経済統計月報』（日本銀行）     |
| 全産業活動指数                     | 季節調整済み前期比 | 『金融経済統計月報』（日本銀行）     |
| 有効求人倍率                      | 倍、季節調整済み  | 『金融経済統計月報』（日本銀行）     |
| 完全失業率                       | 季節調整済み％   | 『金融経済統計月報』（日本銀行）     |
| 所定外労働時間                     | 前年比       | 『金融経済統計月報』（日本銀行）     |
| 雇用者数                        | 前年比       | 『金融経済統計月報』（日本銀行）     |
| 常用雇用者数                      | 前年比       | 『金融経済統計月報』（日本銀行）     |
| 現金給与総額（名目）                  | 前年比       | 『金融経済統計月報』（日本銀行）     |
| 企業物価指数（消費税を除く、夏季電力調整後）      | 前年比       | 『企業物価指数』（日本銀行）       |
| 消費者物価指数（消費税調整済み、除く生鮮食品）     | 前年比       | 『消費者物価指数』（総務省）       |
| 企業向けサービス価格指数（消費税を除く、除く国際運輸） | 前年比       | 『企業向けサービス価格指数』（日本銀行） |
| M2                          | 前年比       | 『金融経済統計月報』（日本銀行）     |
| 企業倒産件数                      | 前年比       | 『金融経済統計月報』（日本銀行）     |

表 4 主成分の抽出に用いた金融変数の一覧

| 変数名称                  | 単位 | 出所               |
|-----------------------|----|------------------|
| 無担保コール・レート（オーバーナイト物）  | 年％ | 『金融経済統計月報』（日本銀行） |
| LIBOR（米ドル）（3 ヲ月）      | 年％ | 『金融経済統計月報』（日本銀行） |
| 金利スワップ・レート（円ー円）（10 年） | 年％ | 『金融経済統計月報』（日本銀行） |
| 金利スワップ・レート（円ー円）（5 年）  | 年％ | 『金融経済統計月報』（日本銀行） |
| 国庫短期証券利回（3 ヲ月）        | 年％ | 『金融経済統計月報』（日本銀行） |
| TIBOR（ユーロ円、1 ヲ月）      | 年％ | 『金融経済統計月報』（日本銀行） |
| TIBOR（ユーロ円、3 ヲ月）      | 年％ | 『金融経済統計月報』（日本銀行） |
| TIBOR（日本円、3 ヲ月）       | 年％ | 『金融経済統計月報』（日本銀行） |
| 東京レポ・レート（翌日物、T+1）     | 年％ | 『金融経済統計月報』（日本銀行） |
| 国債金利（ジェネリック、5 年）      | 年％ | Bloomberg        |
| 国債金利（ジェネリック、10 年）     | 年％ | Bloomberg        |
| 国債金利（ジェネリック、20 年）     | 年％ | Bloomberg        |

|                             |                    |                  |
|-----------------------------|--------------------|------------------|
| 円・実効為替レート（名目）               | 2010 年=100 とする指数   | 『金融経済統計月報』（日本銀行） |
| 円・実効為替レート（実質）               | 2010 年=100 とする指数   | 『金融経済統計月報』（日本銀行） |
| 対顧客為替相場（ユーロ）                | 1 ユーロにつき円          | 『金融経済統計月報』（日本銀行） |
| 対顧客為替相場（ポンド）                | 1 ポンドにつき円          | 『金融経済統計月報』（日本銀行） |
| 対顧客為替相場（韓国ウォン）              | 100 ウォンにつき円        | 『金融経済統計月報』（日本銀行） |
| 東京インターバンク相場（円・ドル）（スポット・レート） | 1 ドルにつき円           | 『金融経済統計月報』（日本銀行） |
| 東証株価指数                      | 1968 年 1 月 4 日=100 | 『金融経済統計月報』（日本銀行） |
| 日経 225 先物終値                 | 円                  | 『金融経済統計月報』（日本銀行） |
| TOPIX 先物終値                  | ポイント               | 『金融経済統計月報』（日本銀行） |

表 5 その他金融経済変数

| 変数名称       | 単位  | 説明                                                                  | 出所                            |
|------------|-----|---------------------------------------------------------------------|-------------------------------|
| 日本銀行の物価見通し | 前年比 | 経済・物価情勢の展望における政策委員の大勢見通し(消費者物価指数<除く生鮮食品、消費税引き上げの影響を除くケース>の中央値)の直近期分 | 日本銀行                          |
| 金融政策ショック   | 年%  | 潜在金利の日次変化<br>(金融政策決定会合前後)                                           | Krippner [2015] <sup>10</sup> |
| 民間の物価予想    | 前年比 | ESP フォーキャスト(日本銀行の物価見通しと予想時期を合わせて使用)                                 | 日本経済研究センター                    |

#### 4. 実証分析

本節では、実証分析の結果を述べる。はじめに、深層学習モデルを用いて定量化した、日本銀行による景気判断のトーンの基本的性質を述べる。次に、日本銀行のトーン・ショックの推定を行い、同ショックが OIS 市場に与えた影響

<sup>10</sup> 大部分のデータは、Krippner [2015]による潜在金利が掲載されているウェブサイト (<https://www.rbnz.govt.nz/research-and-publications/research-programme/additional-research/measures-of-the-stance-of-united-states-monetary-policy/comparison-of-international-monetary-policy-measures>) から取得した。また、同ページに掲載されていない期間(2016 年 2 月 24 日から 11 月 22 日まで)については、クリップナー氏から提供を受けた。




について説明する。日本銀行のトーンは、全期間を対象として、現状評価・先行き評価別に推定した。また、日本銀行のトーン・ショックの推定は、期間を分割したうえで、現状評価・先行き評価別に実施した。具体的には、2008年4月～13年3月（白川前総裁在任期間、以下白川体制期）と2013年4月～17年9月（黒田総裁就任以降の期間、以下黒田体制期）に分割した<sup>11</sup>。

### （１） 推定されたトーンの時系列データ

はじめに、深層学習モデルを用いて推定した日本銀行のトーンの基本的な性質について確認する。具体的には、景気動向指数（2010年基準）との相関関係や、トーン間の相関関係を確認する。

図1および図2は、日本銀行のトーンと景気動向指数の推移、図3は、それらの相関係数を体制期別に示している。図3をみると、白川体制期から黒田体制期にかけて、日本銀行における現状評価のトーンと景気動向指数（一致指数）との相関係数が若干上昇する一方、先行き評価のトーンについては、景気動向指数（先行指数）との相関係数が大きく低下している。


図1 現状評価のトーンと景気動向指数（一致指数）の推移



備考：図中縦線は2013年4月（黒田体制期の始期）を示す。図2も同じ。


<sup>11</sup> 黒田総裁就任以降の期間については、データの制約などから2017年9月までを分析対象とした。

図 2 先行き評価のトーンと景気動向指数（先行指数）の推移



備考：現状評価のトーンは景気動向指数・一致指数、先行き評価のトーンは景気動向指数・先行指数との相関。

図 3 日本銀行のトーンと景気動向指数との相関係数



## (2) 日本銀行のトーン・ショックの抽出

ここでは、2 節 (2) で示した手法を用いて、日本銀行のトーン・ショックを抽出する。具体的には、現状評価または先行き評価のトーンを被説明変数、

金融経済変数の主成分などを説明変数として重回帰分析を行い、その残差としてトーン・ショックを抽出する。

ここで、金融経済変数の主成分の抽出手法について概要を説明する。各変数の利用に当たっては、金融政策決定会合開催時点でのデータの利用可能性を考慮した。すなわち、金融変数は会合開催月の前月までの計数、経済変数は前々月までの計数をそれぞれ用いた。このようにして、各時点で利用可能だった金融経済変数のデータ・ベースを金融政策決定会合ごとに作成し、階差を取った時系列から主成分を抽出した。もっとも、多数の金融経済変数から主成分を抽出する際には、各変数の性質に応じてグループ化することが適切である可能性も考えられる。そこで本研究では、全ての金融経済変数を1つのグループとして扱い、体制期別に主成分を抽出した場合（以下、手法1）と、金融変数と経済変数を分割して別々のグループとして扱ったうえで体制期別に主成分を抽出した場合（以下、手法2）の結果を示した。また、回帰分析における係数推定値の標準誤差に対して、不均一分散に頑健なホワイトの修正を行った（MacKinnon and White [1985]）。このほか、説明変数に用いた主成分は、全変動に対する累積寄与率が50%を超える順位までの主成分を採用した。具体的には、手法1では、白川体制期では第6主成分まで、黒田体制期では第5主成分までを用いた。また、手法2では、白川体制期の経済変数では第6主成分まで、金融変数では第2主成分まで、黒田体制期の経済変数では第5主成分まで、金融変数では第2主成分までを用いた。

最初に、手法1により日本銀行のトーンを分析した結果について説明する。表6および表7は、黒田体制期と白川体制期における回帰分析の結果を示したものである。結果をみると、現状評価・先行き評価ともに複数の主成分が有意となったほか、先行き評価では、日本銀行の物価見通しや民間の物価予想が有意となった。こうした結果から、日本銀行のトーンは、今回用いた説明変数によってある程度説明されており、この回帰分析の残差であるトーン・ショックは、既往情報による成分がある程度適切に除かれたものだと考えられる。

表 6 手法 1 による日本銀行のトーンの分析結果（黒田体制期）

|             | 現状評価   |         |     | 先行き評価  |         |     |
|-------------|--------|---------|-----|--------|---------|-----|
| 定数項         | 0.007  | (0.018) |     | 0.004  | (0.017) |     |
| 日本銀行の物価見通し  |        |         |     | 0.155  | (0.069) | **  |
| 潜在金利        |        |         |     | 0.711  | (0.675) |     |
| 民間の物価予想     |        |         |     | -0.114 | (0.046) | **  |
| 第1主成分       | -0.012 | (0.003) | *** | -0.008 | (0.003) | **  |
| 第2主成分       | 0.006  | (0.003) | **  | 0.003  | (0.005) |     |
| 第3主成分       | 0.011  | (0.006) | *   | 0.026  | (0.008) | *** |
| 第4主成分       | -0.001 | (0.006) |     | 0.003  | (0.008) |     |
| 第5主成分       | 0.005  | (0.007) |     | 0.003  | (0.007) |     |
| 8回MPMダミー    | -0.011 | (0.034) |     | 0.006  | (0.040) |     |
| 観測数         | 53     |         |     | 53     |         |     |
| 自由度修正済み決定係数 | 0.09   |         |     | 0.19   |         |     |

備考：括弧内の数字は標準誤差を表す。また、\*\*\*は 1%水準、\*\*は 5%水準、\*は 10%水準で有意であることを表す。以下、表 7 と同じ。

表 7 手法 1 による日本銀行のトーンの分析結果（白川体制期）

|             | 現状評価   |         |     | 先行き評価  |         |     |
|-------------|--------|---------|-----|--------|---------|-----|
| 定数項         | -0.013 | (0.016) |     | 0.003  | (0.010) |     |
| 日本銀行の物価見通し  |        |         |     | 0.137  | (0.029) | *** |
| 潜在金利        |        |         |     | 1.207  | (0.784) |     |
| 民間の物価予想     |        |         |     | -0.183 | (0.043) | *** |
| 第1主成分       | 0.002  | (0.006) |     | 0.002  | (0.003) |     |
| 第2主成分       | -0.012 | (0.005) | **  | -0.003 | (0.003) |     |
| 第3主成分       | 0.021  | (0.006) | *** | 0.007  | (0.004) | *   |
| 第4主成分       | 0.023  | (0.009) | **  | 0.004  | (0.006) |     |
| 第5主成分       | 0.006  | (0.010) |     | 0.011  | (0.006) | *   |
| 第6主成分       | 0.003  | (0.011) |     | 0.003  | (0.007) |     |
| 臨時MPMダミー    | 0.152  | (0.075) | **  | 0.068  | (0.057) |     |
| 観測数         | 77     |         |     | 77     |         |     |
| 自由度修正済み決定係数 | 0.20   |         |     | 0.16   |         |     |

次に、手法 2 により日本銀行のトーンを分析した結果について説明する。表 8 および表 9 は、黒田体制期と白川体制期における回帰分析結果を示している。表 6 および表 7 と比較すると、手法 1 による分析結果と同様の結果であることがわかる。

表 8 手法 2 による日本銀行のトーン分析結果（黒田体制期）

|             | 現状評価   |         |    | 先行き評価  |            |
|-------------|--------|---------|----|--------|------------|
| 定数項         | 0.009  | (0.018) |    | 0.008  | (0.018)    |
| 日本銀行の物価見通し  |        |         |    | 0.173  | (0.068) ** |
| 潜在金利        |        |         |    | 0.653  | (0.605)    |
| 民間の物価予想     |        |         |    | -0.080 | (0.044) *  |
| 経済第1主成分     | 0.008  | (0.003) | ** | 0.004  | (0.006)    |
| 経済第2主成分     | -0.005 | (0.008) |    | -0.020 | (0.009) ** |
| 経済第3主成分     | 0.004  | (0.007) |    | 0.019  | (0.007) ** |
| 経済第4主成分     | -0.004 | (0.007) |    | 0.011  | (0.010)    |
| 経済第5主成分     | -0.008 | (0.011) |    | -0.012 | (0.010)    |
| 金融第1主成分     | -0.010 | (0.004) | ** | -0.004 | (0.004)    |
| 金融第2主成分     | -0.014 | (0.008) | *  | -0.020 | (0.008) ** |
| 8回MPMダミー    | -0.018 | (0.037) |    | -0.009 | (0.036)    |
| 観測数         | 53     |         |    | 53     |            |
| 自由度修正済み決定係数 | 0.06   |         |    | 0.21   |            |


表 9 手法 2 による日本銀行のトーン分析結果（白川体制期）

|             | 現状評価   |         |     | 先行き評価  |             |
|-------------|--------|---------|-----|--------|-------------|
| 定数項         | -0.014 | (0.017) |     | 0.004  | (0.010)     |
| 日本銀行の物価見通し  |        |         |     | 0.125  | (0.034) *** |
| 潜在金利        |        |         |     | 1.673  | (0.762) **  |
| 民間の物価予想     |        |         |     | -0.168 | (0.055) *** |
| 経済第1主成分     | 0.017  | (0.005) | *** | 0.006  | (0.003) *   |
| 経済第2主成分     | 0.015  | (0.010) |     | 0.011  | (0.006) **  |
| 経済第3主成分     | 0.002  | (0.011) |     | -0.003 | (0.007)     |
| 経済第4主成分     | -0.011 | (0.011) |     | -0.012 | (0.007)     |
| 経済第5主成分     | -0.015 | (0.009) | *   | -0.005 | (0.007)     |
| 経済第6主成分     | -0.003 | (0.010) |     | 0.003  | (0.006)     |
| 金融第1主成分     | 0.005  | (0.007) |     | 0.004  | (0.003)     |
| 金融第2主成分     | -0.016 | (0.011) |     | -0.004 | (0.006)     |
| 臨時MPMダミー    | 0.165  | (0.078) | **  | 0.077  | (0.061)     |
| 観測数         | 77     |         |     | 77     |             |
| 自由度修正済み決定係数 | 0.16   |         |     | 0.17   |             |


次に、回帰分析の残差として抽出されるトーン・ショックの推移を示す。図 4 は手法 1 による結果、図 5 は手法 2 による結果である。手法 1 と手法 2 で推定されたトーン・ショックの相関係数を体制期別に算出したところ、現状評価と先行き評価ともに両体制期において 0.9 以上であった。

図 4 手法 1 により抽出した日本銀行のトーン・ショック

(a) 現状評価




(b) 先行き評価




備考:金融政策決定会合開催日の間隔が均等になるようにプロットしている。図 5 も同じ。

図 5 手法 2 により抽出した日本銀行のトーン・ショック

(a) 現状評価



(b) 先行き評価



### (3) 日本銀行のトーン・ショックが OIS 市場に与えた影響

最後に、日本銀行のトーン・ショックが、OIS レートに与えた影響の分析結果について説明する。特に本研究では、トーン・ショックが OIS レートのボラティリティに与えた影響に注目する。よって、EGARCH モデルで表現されたボラティリティにおける、日本銀行における先行き評価のトーン・ショックの係数について、体制期別の推定結果を確認した。また、EGARCH モデルの推定にあたっては、誤差項が従う分布が未知の場合に便利な疑似最尤法を、正規分布を想定して用いた (Bollerslev and Wooldridge [1992])<sup>12</sup>。


図 6 は、手法 1 により主成分を抽出した場合の結果を示している。結果をみると、白川体制期、黒田体制期ともに、ボラティリティの変動に対する日本銀

<sup>12</sup> 疑似最尤法の推定値は、サンプル数が少ないときの性質は必ずしも明確ではないが、漸近的には一致性を満たす。


行における先行き評価のトーン・ショックの係数は概ね負と推定された。もっとも、白川体制期では、ほぼ全ての満期で推定値が有意とならなかった一方、黒田体制期では、多くの満期（12 満期のうち 9 満期）で推定値が 5%有意であった。

図 6 手法 1 による日本銀行における先行き評価のトーン・ショックの係数

(a) 黒田体制期



(b) 白川体制期



備考：各点上下のバーは、95%信頼区間を示している。図 7 も同じ。


また、頑健性チェックとして、手法 2 により主成分を抽出した場合の結果を確認したところ、図 7 のとおり、手法 1 による結果と概ね同様となった。

これらの結果から、日本銀行における先行き評価について正のトーン・ショックが発生すると、市場参加者の間において、政策金利の先行き不透明感が低下することが確認された<sup>13</sup>。


<sup>13</sup> これは、日本銀行による強めの景気判断が、OIS 市場では、先行き 1 年間ににおける金融政策の不透明感を低下させたことを示す。この関係は、金融政策の先行き不透明感が、利

図 7 手法 2 による日本銀行における先行き評価のトーン・ショックの係数

(a) 黒田体制期



(b) 白川体制期



備考：黒田体制期における満期 6・7 カ月の係数は未収束のため参考値である。

## 5. まとめと今後の課題

本研究では、深層学習モデルを用いて、日本銀行による景気判断のトーンを定量化した。さらに、日本銀行のトーンに含まれる、既往情報から予想できない付加情報による成分であるトーン・ショックを抽出した。そして、EGARCH モデルを用いて、日本銀行のトーン・ショックが OIS 市場に与えた影響を分析した。

本研究の貢献は以下の 2 点である。第 1 に、先行研究のトーン・ショック抽出手法を精緻化し、より適切にトーン・ショックを評価する手法を提案した。

---

上げへの転換ではなく、追加緩和策の有無に起因する状況において生じ得るものと思われる。



Hubert and Labondance [2017]の手法では、トーン・ショックの抽出に際して、一部の代表的な金融経済変数のみを既往情報として考慮している。このため、景気判断のトーンに含まれる既往情報が十分に除外されず、トーン・ショックが過大評価されている可能性が考えられる。本研究では、多数の金融経済変数の主成分を説明変数として用いることで、景気判断のトーンに含まれる既往情報を極力除外し、トーン・ショックをより適切に抽出することを試みた。第2に、黒田体制期について、日本銀行における先行き評価に関する正のトーン・ショックが生じると、OIS レートのボラティリティが低下する関係を見出した。

最後に、今後の研究課題について述べる。第1に、トーン・ショックの影響分析の拡充である。本研究では、日本銀行のトーン・ショックがOIS 市場へ与える影響を分析したが、その他の金融市場や経済変数などへの影響を分析することで、さまざまなチャネルを通じたトーン・ショックの影響を包括的に評価できると考えられる。第2に、日本銀行のトーン・ショックがメディア報道に及ぼす影響の分析である。総裁定例記者会見における景気判断が、メディア報道を通じて、民間経済主体一般にどのように受けとめられたかを把握しておくことは、中央銀行がコミュニケーション戦略を運営するうえで重要である。第3に、トーン以外のテキストの特徴の分析である。情報発信者の主観などを表すモダリティや読みやすさなど、本研究で対象としなかったテキストの特徴を分析することで、日本銀行の景気判断が金融市場に与える影響について、より深い理解が得られる可能性がある。

## 参考文献

- 岡谷貴之、杉山 将編『深層学習』、機械学習プロフェッショナルシリーズ、講談社、2015 年
- 翁 邦雄・白塚重典・藤木 裕、「ゼロ金利政策：現状と将来展望—中央銀行エコノミストの視点—」、深尾光洋・吉川 洋編『ゼロ金利と日本経済』第 2 章、日本経済新聞社、2000 年、33～76 頁
- 鎌田康一郎、「中央銀行の情報発信と市場心理：2013 年中の日米における 2 つのエピソードを巡って」、日銀リサーチラボ No.14-J-1、日本銀行、2014 年
- 五島圭一・高橋大志、「ニュースと株価に関する実証分析—ディープラーニングによるニュース記事の評判分析—」、『証券アナリストジャーナル』第 54 巻第 3 号、日本証券アナリスト協会、2016 年、76～86 頁
- ・———・山田哲也、「自然言語処理による景況感ニュース指数の構築とボラティリティ予測への応用」、金融研究所ディスカッション・ペーパーNo. 2019-J-3、日本銀行金融研究所、2019 年
- 坪井祐太・海野裕也・鈴木 潤、杉山 将編『深層学習による自然言語処理』、機械学習プロフェッショナルシリーズ、講談社、2017 年
- 中島上智・服部正純、「新日銀法 10 年間ににおける情報発信の影響に関する一考察」、『金融研究』第 29 巻第 2 号、日本銀行金融研究所、2010 年、1～26 頁
- 山本裕樹・松尾 豊、「景気ウォッチャー調査の深層学習を用いた金融レポートの指数化」、『2016 年度人工知能学会全国大会論文集』、2016 年
- Bernanke, Ben S., and Frederic S. Mishkin, “Inflation Targeting: A New Framework for Monetary Policy?” *Journal of Economic Perspectives*, 11(2), 1997, pp. 97–116.
- Bholat, David, Stephen Hansen, Pedro Santos, and Cheryl Schonhardt-Bailey, “Text Mining for Central Banks,” Centre for Central Banking Studies Handbook No. 33, Bank of England, 2015.
- Blinder, Alan S., *Central Banking in Theory and Practice*, The MIT Press, 1998.
- , Michael Ehrmann, Marcel Fratzscher, Jakob De Haan, and David-Jan Jansen,

- “Central Bank Communication and Monetary Policy: A Survey of Theory and Evidence,” *Journal of Economic Literature*, 46(4), 2008, pp. 910–945.
- Bollerslev, Tim and Jeffrey M. Wooldridge, “Quasi-maximum Likelihood Estimation and Inference in Dynamic Models with Time Varying Covariances,” *Econometric Reviews*, 11(2), 1992, pp. 143–172.
- Bulíř, Aleš, Martin Čihák, and Kateřina Šmídková, “Writing Clearly: ECB’s Monetary Policy Communication,” *German Economic Review*, 14(1), 2013, pp. 50–72.
- Ehrmann, Michael, and Jonathan Talmi, “Starting from a Blank Page? Semantic Similarity in Central Bank Communication and Market Volatility,” ECB Working Paper Series No. 2023, European Central Bank, 2017.
- , and Marcel Fratzscher, “Explaining Monetary Policy in Press Conferences,” *International Journal of Central Banking*, 5(2), 2009, pp. 41–84.
- Goodfellow, Ian, Yoshua Bengio, and Aaron Courville, *Deep Learning*, The MIT Press, 2016.
- Hansen, Stephen, and Michael McMahon, “Shocking Language: Understanding the Macroeconomic Effects of Central Bank Communication,” *Journal of International Economics*, 99 Supplement 1, 2016, pp. S114–S133.
- Hendry, Scott, and Alison Madeley, “Text Mining and the Information Content of Bank of Canada Communications,” Bank of Canada Working Paper 2010-31, Bank of Canada, 2010.
- Hubert, Paul, and Fabien Labondance, “Central Bank Sentiment and Policy Expectations,” Staff Working Paper No. 648, Bank of England, 2017.
- Jegadeesh, Narasimhan, and Di Wu, “Deciphering FedSpeak: The Information Content of FOMC Meetings,” 2017 (available at SSRN: <https://ssrn.com/abstract=2939937> or <http://dx.doi.org/10.2139/ssrn.2939937>).
- Kawamura, Kohei, Yohei Kobashi, Masato Shizume, and Kozo Ueda, “Strategic Central Bank Communication: Discourse Analysis of the Bank of Japan’s Monthly Report,” *Journal of Economic Dynamics and Control*, 100, 2019, pp. 230–250.
- Krippner, Leo, *Term Structure Modeling at the Zero Lower Bound: A Practitioner’s*

*Guide*, Palgrave Macmillan, 2015.

Levin, Andrew, David López-Salido, Edward Nelson, and Tack Yun, “Limitations on the Effectiveness of Forward Guidance at the Zero Lower Bound,” *International Journal of Central Banking*, 6(1), 2010, pp. 143–189.

MacKinnon, James G., and Halbert White, “Some Heteroskedasticity-consistent Covariance Matrix Estimators with Improved Finite Sample Properties,” *Journal of Econometrics*, 29(3), 1985, pp. 305–325.

Milea, Viorel, Rui J. Almeida, Nurfadhlin Mohd Sharef, Uzay Kaymak, and Flavius Frasincar, “Computational Content Analysis of European Central Bank Statements,” *International Journal of Computer Information Systems and Industrial Management Applications*, 4, 2012, pp. 628–640.

Nelson, Daniel B., “Conditional Heteroskedasticity in Asset Returns: A New Approach,” *Econometrica*, 59(2), 1991, pp. 347–370.

Romer, Christina D., and David H. Romer, “A New Measure of Monetary Shocks: Derivation and Implications,” *American Economic Review*, 94(4), 2004, pp. 1055–1084.

Svensson, Lars E.O., “Inflation Forecast Targeting: Implementing and Monitoring Inflation Targets,” *European Economic Review*, 41(6), 1997, pp. 1111–1146.

Tobback, Ellen, Stefano Nardelli, David Martens, “Between Hawks and Doves: Measuring Central Bank Communication,” ECB Working Paper Series No. 2085, European Central Bank, 2017.

Woodford, Michael, “Monetary Policy in the Information Economy,” paper presented at the Federal Reserve Bank of Kansas City’s Economic Policy Symposium on “Economic Policy for the Information Economy,” in Jackson Hole on August 30 – September 1, 2001.

Zhang, Xiang, Junbo Zhao and Yann LeCun, “Character-level Convolutional Networks for Text Classification,” *Advances in Neural Information Processing Systems*, 28, 2015, pp. 649–657.

## 補論. 文字単位の畳み込みニューラル・ネットワーク・モデル

本研究では、テキストの定量化に際して、Zhang, Zhao, and LeCun [2015]が提案した深層学習モデルである、文字単位の畳み込みニューラル・ネットワーク・モデルを用いた。以下では、同モデルの概要を解説する。


深層学習モデルとは、ニューラル・ネットワーク・モデルを複数層積み重ねたモデルである。ニューラル・ネットワーク・モデルとは、データの入出力を有する学習素子を、生物の神経回路を模して組み合わせたネットワーク構造をもつモデルである。また、畳み込みニューラル・ネットワーク (Convolutional Neural Network: CNN) ・モデルは、ニューラル・ネットワーク・モデルのなかでも、画像のような局所的な構造をもつ対象のパターン認識に強いとされるモデルである。CNN モデルでは、フィルタと呼ばれる、入力画像よりも小さいサイズの画像が用意され、入力画像とフィルタとの間で「畳み込み」と呼ばれる演算を行い、情報を縮約することで、入力画像から特定のパターンを抽出することを試みる。CNN モデルでは、教師データを学習して各フィルタのウェイトを決定する。CNN モデルそのもののアルゴリズムについてはここでは触れないが、例えば、Goodfellow, Bengio, and Courville [2016]や岡谷 [2015]、坪井・海野・鈴木 [2017] に詳しく解説されている。

文字単位の CNN モデルは、画像処理のために開発された CNN モデルを、パターン認識に関する強力な性能に着目してテキスト処理に応用したモデルの 1 つである。テキスト処理のモデルとしての最大の特徴点は、テキストを文字ごと (character-level) に細分化して処理することである。このメリットは、大別して 2 つある。第 1 に、形態素解析が不要となる。本研究が対象としている日本語では、英語とは異なり、テキストが単語単位で区切られていない。よって日本語のテキストを分析する場合には、一般的に前処理としてテキストを単語別に分割 (形態素解析) する必要がある。この点、文字単位の CNN モデルでは、入力するテキストから文字の並び順、出現位置、共起関係などを直接的に学習するため、形態素解析が不要となる。第 2 に、教師あり学習の効率性が向上する。一般的に、文字の組み合わせから構成される単語の数は、文字の数と比べ、膨大な数となる。このため、単語を処理単位としてテキストを分析する場合、教師データに含まれていない単語 (未知語) がテキストに存在する可能性が高い。この点、文字を処理単位とする場合には、教師データに含まれていない文字が存在する可能性は比較的低く、効率的に学習することができる。

CNN に基づくテキスト処理モデルでは、入力であるテキスト (本研究では、句点から次の句点までの 1 文) を行列で表現したうえで、テキストとフィルタ

との間で1次元の畳み込み演算が行われる。ここで、テキスト分析におけるフィルタとは、テキストの処理単位を複数まとめたものとして表現される。本研究で用いた文字単位のCNNモデルでは、1文字ごとがテキストの処理単位となっているため、2文字ごとや3文字ごとといった特定の文字数ごとの文字列がフィルタとなる（入力層＜テキストをCNNモデルに入力する層＞の場合）。このようにテキストから各フィルタに情報を縮約することで、テキストから特定のパターンを抽出する。その概念図を図A-1に示している。この処理が入力層だけではなく、中間層の1層、2層と繰り返されることで、テキストの情報がさらに縮約されていく。

図 A-1 入力層の拡大図



備考：左側長方形の上方にあるグレーの大きな四角形がフィルタ（フィルタの幅は5文字分）を表す。

テキストの定量化に際しては、まずテキストを文字ごとに分解し、各文字をワンホット・ベクトルで表現したうえで、それらを行方向に並べることによって、テキストの行列表現を得る<sup>14</sup>。このとき、個々のテキストで文字数が異なるため、分析対象におけるテキストの最大文字数を行列の行数とし、行数が不足するテキストについてはパディングすることで、行数を統一する<sup>15</sup>。一方、

<sup>14</sup> ワンホット・ベクトルとは、ここでは、表現したい文字 $a_i (1 \leq i \leq n)$ に対応して、 $i$ 番目の要素だけが1でそれ以外の要素を0とする、 $1 \times n$ の横ベクトルのことである。

<sup>15</sup> パディングとは、テキストを一定のサイズの行列に変換する際に、不足する部分に同一の特殊文字や数字を追加することで次元を合わせることである。なお、Zhang, Zhao, and

列数（ワンホット・ベクトルの次元数）については、分析対象とするテキストに含まれる文字の種類と同一に設定すればよい。なお、Zhang, Zhao, and LeCun [2015]では、英語を対象としていることから、文字の種類はアルファベット 26 文字、アラビア数字 10 文字、その他特殊文字 34 文字の計 70 文字である一方、本研究では、日本語を対象としているため文字の種類（ひらがな、カタカナ、漢字など）が多く、計 2,587 文字となっている。

本研究では、Zhang, Zhao, and LeCun [2015]と同様に、入力層と出力層に加えて、全 8 層の中間層からなる深層学習モデルを用いた。上述のとおり、本研究ではワンホット・ベクトルの次元が非常に大きいため、入力層について Zhang, Zhao, and LeCun [2015]のモデルに修正を加えた。具体的には、埋め込み層と呼ばれる層を通すことで、入力ベクトルを 2,587 次元から 70 次元に変換した。8 層の中間層は、6 層の畳み込み層と 2 層の全結合層からなる。さらに、中間層において、1 層目、2 層目、6 層目の畳み込み層の後には、最大値プーリング層と呼ばれる層を挟んでいるほか、7 層目および 8 層目の全結合層からの出力に対してドロップ・アウトを適用し、過学習を防いでいる<sup>16, 17</sup>。テキストに対して景気の評価を表す数値を出力するモデルに対しては、出力層に線形関数を用いたほか、テキストが現状あるいは先行きのどちらのトピックに近いかを表す確率を出力するモデルに対しては、出力層にシグモイド関数を用いた<sup>18</sup>。本研究における深層学習モデルのネットワーク構造の概略図を図 A-2 に示している。

なお、深層学習モデルには、訓練データからの学習では決定されないため、人間が事前に設定する必要があるハイパー・パラメータが存在する。本研究の同パラメータは、Zhang, Zhao, and LeCun [2015]と同じ値とした。また、モデルの実装には、Python の深層学習モデル・ライブラリである Keras を用いた<sup>19</sup>。

---

LeCun [2015]では英文を実験対象としていたため、1 つのテキストに含まれる文字数の最大値が大きく、1,014 文字で切り捨てている一方、本研究で取り扱うテキストでは 356 文字であったため、切捨ては行わなかった。

<sup>16</sup> 最大値プーリングは、与えられたデータから最大値を出力する演算のこと。

<sup>17</sup> ドロップ・アウトとは、学習時にノードの一部を 0 とすることで、特定のノードだけを重視した学習を防ぐ方法であり、学習中の微分計算の度に、無作為にノードを抽出することで、異なる部分構造を評価しパラメータを更新する。

<sup>18</sup> シグモイド関数は、0 から 1 までの値を取る関数であるため、出力値をトピック確率として解釈できる。

<sup>19</sup> Keras は同ライブラリのウェブサイト (<https://keras.io/>) より入手可能である。

図 A-2 本研究における深層学習モデルのネットワーク構造の概略図

