

IMES DISCUSSION PAPER SERIES

人工知能とテキスト・データを活用した数量分析

しおの たかし
塩野剛志

Discussion Paper No. 2018-J-9

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。

人工知能とテキスト・データを活用した数量分析

しおの たかし
塩野剛志*

要 旨

本稿では、近年マクロ経済分野への応用が進んでいる人工知能（AI）技術とテキスト・データを活用した数量分析の事例として、「マイナス金利政策インデックス」と「物価ニュース・インデックス」の構築法を示し、比較分析を行う。前者は、日本銀行が 2016 年 1 月に導入を決定した「マイナス金利政策」に対するセンチメントを、政府・日銀公表文書、国会会議録、経済ニュース記事から、単語の分散表現の手法を用いて日次で数値化した指標である。計測結果は、平均的にネガティブであったものの、2016 年 9 月の「長短金利操作」導入に伴う長期金利の上昇に伴い、ネガティブの度合いは趨勢的に薄れてきている。これは、日本銀行の「総括的検証」で示された見解とも整合的である。後者は、経済ニュース記事から、現在の物価動向を日次で推計（ナウキャスト）する指標である。具体的には、物価関連ニュース記事からコア CPI 前月比の動きに関係する特徴を抽出するよう AI を訓練し、訓練済 AI に最新のニュース記事を入力することで、コア CPI 統計公表前に現在の物価動向をナウキャストする。月次での計測結果、単純な時系列モデルよりも高い精度が確認された。

キーワード：自然言語処理、分散表現、センチメント分析、ニューラルネットワーク、深層学習、LSTM、ナウキャストイング

JEL classification: C43、C45、E37

* クレディ・スイス証券経済調査部エコノミスト (E-mail: takashi.shiono@credit-suisse.com)

本稿は、2017 年 4 月に日本銀行金融研究所が開催した「マイナス金利環境におけるファイナンス研究の展開」をテーマとするファイナンス・ワークショップへ白川・塩野 [2016, 2017a] を基に提出した論文に、加筆・修正を施したものである。上田晃三教授（早稲田大学）をはじめ、同ワークショップ参加者から貴重なコメントを頂戴した。また、修正稿に対し、匿名の査読者から建設的なコメントを多く頂戴し、分析の幅を広げることができた。記して感謝したい。ただし、本稿で示された意見・内容は筆者個人に属し、日本銀行あるいはクレディ・スイス証券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個人に属する。

1. はじめに

人工知能（Artificial Intelligence: AI）技術とテキスト・データの活用は、市場価格の予想を目的とした実践から始まり、徐々にマクロ経済分野への応用も進みつつある。近年、わが国においても、テキスト・データと機械学習を用いた金融市場分析が盛んになってきている。日本語テキストを用いた先行研究では、株価などの市場価格の予想を目的とした応用が主流となっている。例えば、和泉・後藤・松井 [2011] は、日本銀行の金融経済月報から、共起（co-occurrence）、主成分（principal component）、回帰（regression）の各分析を組み合わせた CPR 法と呼ばれる方法で特徴を抽出し、為替、債券、株式市場の価格変動を予想に用いている。また、吉原ほか [2014] は、金融市場ニュースを RNN-RBM (Recurrent Neural Networks Restricted Boltzmann Machine) に読み込ませ、株価の予想に応用している。片倉・高橋 [2015] は、株式市場ニュースから CBOW (Continuous Bag of Words) によって単語の分散表現を獲得し、株式市場のファクター・リターンとの相関を分析している。いずれの研究も、テキスト・データと機械学習の金融市場分析における有用性を示している。

他方、伝統的なマクロ分析においても、海外を中心にテキスト・データの活用が進みつつある。例えば、Baker, Bloom, and Davis [2016] は、経済ニュース記事に出てくる単語の分布から、経済政策の不確実性を測る指標を作成している。また、Balke, Fulmer, and Zhang [2017] は、米国地区連銀がまとめるページェブックの文章を数値化し、鉱工業生産や雇用者数などの経済データと合わせて実質 GDP の 1 期先予測を行った結果、テキスト情報を含まないモデルと比べて予測精度が向上したことを報告している。さらに、Thorsrud [2016] は、経済ニュース記事を LDA (Latent Dirichlet Allocation) によって数値化したうえで、GDP 成長率と合わせて動的ファクター・モデルの観測変数とし、両データの共通変動成分を推定した。そのうえで、このように抽出した共通変動成分の系列を日次景気一致指数として指数化した。一方、Shiller [2017] は、経済学研究の大きな流れとして、機械学習などの分析手法の発達や利用可能なビッグデータの蓄積を受けて、テキストのような非数値データの活用が重要になると主張している。特に、マクロ経済の変動には時々刻々とした物語（Narratives）の社会的伝播が深く関わっているが、そうした要因は伝統的な経済統計では計測できず、これまで分析対象にならなかった。テキスト分析はこうした経済変動メカニズムのより深い理解のためにも重要だと主張している。

日本におけるマクロ経済分野への応用としては、高杉・山名 [2016] が、国会議事録から経済指標と相関の高い単語の組（N-gram）を特定し、GDP やインフレ率の回帰分析にその出現回数を説明変数として用いた。その結果、単純な

AR モデルによる予測を上回る予測精度が得られたと報告している。より経済学的な研究として、Shibamoto [2016]は、金融政策が市場に影響する経路としてコミュニケーション・チャンネルを重視し、構造ショックの識別において日本銀行発表文書のテキスト・マイニングを活用した。その他、塩野 [2016] は、日本銀行の公表文書が、次回決定会合での政策変更を示唆するか否か分類するニューラルネットを深層学習により構築し、一定の示唆が得られることを確認した。以上のように、テキスト・データの活用は、金融市場分析から始まり、徐々にマクロ経済分野への応用も進みつつある。

こうした潮流を受けて、白川・塩野 [2016] では、日本銀行が 2016 年 1 月に導入を決定した「マイナス金利政策」に対して市場参加者が抱くイメージを数値化した指標を「マイナス金利政策インデックス」と呼称して開発しており、白川・塩野 [2017b] でその内容を統計学界の関係者に紹介している。また、白川・塩野 [2017a] では、ニューラルネット型の AI を活用し、日々の経済ニュース記事から、現在の物価動向を推計（ナウキャスト）する「物価ニュース・インデックス」を開発している。本稿では、2017 年 4 月の日本銀行金融研究所主催ファイナンス・ワークショップ「マイナス金利環境におけるファイナンス研究の展開」におけるこれらの論文に対する議論などを踏まえ、さまざまな対照指標の構築と比較分析を加えて検証を進めた結果を示す。具体的には、マイナス金利政策インデックスについては、白川・塩野 [2016] で論じた評価極性値の平均値で構成されるインデックスの推計に加え、評価極性が付された具体的なテキストの実例を示し、評価極性値のばらつきを計測しているほか、他の手法とのさまざまな対照実験や「長短金利操作インデックス」の構築・推計も行っている。物価ニュース・インデックスについては、分析の頑健性を高めるために白川・塩野 [2017a] よりも予測期間を延長しているほか、モデルから求めたインデックスの値とニュース記事テキストとの整合性を確認している。具体的には、物価ニュース・インデックスが上位 1% あった日と下位 1% にあった日の物価関連ニュース記事のうち、上昇関連記事と下落関連記事のタイトルをすべて抽出し、シェアの差から求められる DI とインデックスとを比較することで、その整合性を確認している。

以下、2 節では「マイナス金利政策インデックス」とその拡張と対照実験について、作成手法を解説した後、最近の推移を分析・考察する。3 節では「物価ニュース・インデックス」とその拡張について、作成手法を解説するとともに、最近の推移を分析・考察する。4 節では、本稿の分析で得られた結果をまとめたうえで、今後の展望を述べる。

2. 「マイナス金利政策インデックス」の作成、推移と含意

白川・塩野〔2016〕では、人工知能（ニューラルネットワーク）型のアルゴリズムなどを応用し、経済ニュース記事、政府・日本銀行公表文書、国会会議録などのテキスト・データから、「マイナス金利」という単語に対するセンチメント（ポジティブ、ネガティブ）を抽出し、数値化する分析を行っている。数値化した指数を「マイナス金利政策インデックス」と呼称し、政府、日本銀行、国会やメディアにおけるマイナス金利政策のイメージがポジティブかネガティブか、その時系列的な推移を計測している。こうした試みは、市場参加者が、日々の業務の中で、「マイナス金利」に関する日本語の情報ソースに触れた時に抱くであろうイメージを可視化することを目的としたものである。

日本銀行公表文書からは政策の有効性の説明や自己評価が、政府文書からは金融政策への信頼度合いや期待等が、国会・メディアからの情報からは、議員や記者を通じて代弁された一般国民や一般的な市場参加者の政策へのイメージが、それぞれ発信されている。個別の市場参加者は、日々リアルタイムに、これら各種チャネルから発信される情報をもとに、現行の金融政策に対して肯定的／否定的といったセンチメントを形成しつつ、さまざまな業務に取り組んでいると思われる。

このような、発信されたテキスト情報を受け取った市場参加者が、何らかのセンチメントを形成するプロセスを、機械学習的な手法を通じて、単純化したモデルとして表現することで、定量的なセンチメント・インデックスを作成した。以下では、同インデックスの作成方法について解説した後、いくつかの対照実験も行う。

（1） テキスト・データ（文書）の取得

「マイナス金利政策インデックス」の推計に使用するテキスト・データは、2016年1月1日～2017年3月8日までの、経済ニュース記事、政府・日本銀行発表文書、国会会議録から、「マイナス金利」という単語を含む文書を抽出したものである。

具体的には、経済ニュース記事については、日本経済新聞、ブルームバーグ、ロイターのウェブサイトを対象に「マイナス金利」という単語を含む記事のみを Google Custom Search を用いて抽出した。政府公表文書については、「月例経済報告」、経済財政諮問会議の「議事要旨」と「大臣記者会見要旨」および「財務大臣記者会見」を対象とし、また、日本銀行の公表文書については、「決定

会合声明文」、「展望レポート」、「主な意見」、「決定会合・議事要旨」、「総裁記者会見記録」、「総裁挨拶・講演記録」、「金融システムレポート」を対象として「マイナス金利」の含まれる文書のみを抽出した。国会会議録についても「マイナス金利」を条件にキーワード検索を行い、該当議事を収集した。

なお、テキスト・データの数値化は日次で行うが、その際、観測日を含む過去 30 日分の文書をまとめて 1 つの入力コーパス（文書群）とする（図表 1）。これによって、日によって発表される文書が異なることによる語彙量の変動を、ある程度抑える効果が期待される。

（２）「マイナス金利」の連想語リストの作成

続いて、Word2Vec という人工知能（ニューラルネットワーク）型のアルゴリズムを用い、コーパスごとに「マイナス金利」から連想される単語のリスト（上位 100 語）を取得する（図表 2）。

Word2Vec を用いれば、入力したコーパスの中で「マイナス金利」という単語が出てくる文脈を読み取り、その文脈上の意味と関連度の高い単語（以下、連想語と呼ぶ）のリストを出力できる。すなわち、「マイナス金利」に前向きなイメージを持っている文章群（コーパス）からの連想語リストには「効力」、「後押し」などポジティブな単語が多く含まれる一方、マイナス金利に後ろ向きなコーパスからは「失望」、「副作用」などネガティブな単語が多くなる。

なお、Word2Vec の詳しい解説は補論 1 に譲るが、同アルゴリズムは 1 つの単語を 200 次元程度の実数値ベクトルに変換する¹。いったん、単語がベクトルに変換されれば、単語間の足し算・引き算を行ったり、相関（一般的にコサイン類似度を使用）を計算することができる。上述の「連想語リスト」を作成する際には、各コーパスに含まれる全ての単語と「マイナス金利」との相関を計算し、相関の高い順に並べている。

¹ 文書をベクトル化する方法としては、tf-idf などのアルゴリズムもある。tf-idf は文書内の各単語に重要度を付すことで、文書を単語重要度の分布とみなすものである。tf-idf では複数文書間の相関をコサイン類似度によって表すことは可能であるが、各単語はスカラー量で表現されるため、特定の文書内における単語間の相関を計算することはできない。単語間の相関を測ることができる点が Word2Vec の利点の一つである。

(3) 「マイナス金利」の連想語の極性（ポジティブ、ネガティブ）

「マイナス金利」の連想語リストが得られたら、それぞれの連想語が、ポジティブな言葉か、ネガティブな言葉かを評価したポイントを付し、コーパスごとに集計する。これによって、日次で 1 つの評価ポイントが定まり、時系列インデックスが得られる（図表 3）。

この際、連想語リストに登場する多数の単語について、ポジティブ (+1) な言葉か、ネガティブ (-1) な言葉か、もしくはニュートラル (0) かという「極性値」（＝評価ポイント）を対応させる辞書（評価極性辞書）が必要となる。ここでは、東北大学 乾・岡崎研究室による「日本語評価極性辞書（用語編および名詞編）」（1 万 8,569 語、以下、東北大辞書）²を基に、Word2Vec を応用することで辞書のカバレッジを Wikipedia コーパスに含まれる全単語にまで拡張した。

なお、Wikipedia コーパス³とは、日本語版 Wikipedia に掲載されている全ての記事を集めたテキスト・データであり、2016 年 7 月 1 日時点で総記事数は 102 万件を超えている。著作権フリーの大規模テキスト・データとして自然言語処理や機械学習の分野で広く活用されている。分析に使用する品詞は「名詞」、「動詞」、「形容詞」、「形容動詞」に限っており、そのため、Wikipedia コーパスでもそれ以外の品詞の単語は削除した。それでも総単語数（重複なし）は 96 万 3,051 語に上る⁴。これだけ大規模な評価極性辞書があれば、収集した各文書の「マイナス金利」連想語のほぼ全てに極性値を付すことができる。

上述のとおり、東北大辞書を基に「Wikipedia 評価極性辞書（96 万 3,051 語）」を作成するが、この際にも Word2Vec を活用する。具体的には、Wikipedia コーパス（品詞抽出済）の単語（96.3 万語）それぞれについて、東北大辞書に掲載されている全ての単語（1.85 万語）との相関を計算し、最も相関の高い語の極性値（-1、0、+1）を付与した（図表 4）。例えば、「政策」というマイナス金利連想語は、Wikipedia コーパスには登場するが、東北大辞書には載っていない。そこで、東北大辞書に載っている語の中で最も「政策」と相関の高い語を調べると「施策」であった。「施策」の極性値はニュートラル (0) であるため、「政策」の値もニュートラル (0) とした。

² 詳細は、小林ほか [2005]、東山・乾・松本 [2008] を参照。

³ <https://dumps.wikimedia.org/jawiki/latest/>

⁴ 大学生を対象にした理解語彙数調査では、大学生の平均語彙数は、3～4 万語とされている（荻原 [2014]）。

Word2Vec の文脈読解が十分なレベルにあれば、このような置き換えによって得た極性値も概ね妥当なものとなる。しかし、念のために、評価する連想語が東北大辞書に載っておらず、**Wikipedia** コーパスとアルゴリズムによる変換が行われたケースについては、手動でその極性値を確認し、明らかに誤った極性値が付されている場合には修正している。

（４）「マイナス金利政策インデックス」の推計

以上のプロセスを経て作成した文書ごとの「マイナス金利連想語リスト」と「**Wikipedia** 評価極性辞書」を用いて「マイナス金利政策インデックス」を推計する。

具体的には、コーパスごとの「マイナス金利連想語」（関連上位 100 語）に極性値を付したうえで、関連（コサイン類似度）をウェイトとして加重平均した。このため、「マイナス金利」と関連が高い単語ほど大きいウェイトが付与され、その極性値が集計ポイントに大きく寄与する。なお、ポイントの解釈は集計後も維持されるため、プラス域ならポジティブ、0 ならニュートラル、マイナス域ならネガティブなイメージと解釈できる。実際に推計された日次の「マイナス金利政策インデックス」は図表 5 のようになった。

同指数の平均的な水準はマイナスとなっており（17 年 3 月 8 日時点で -0.027 ）、マイナス金利政策に対する一般的イメージはネガティブなものであることが示されている。

同指数の推移を見ると、ネガティブ圏からスタートして、2016 年初夏（Brexit 後）にかけて特に落ち込んだ。その後、日本銀行が「総括的検証」を行うことを決めてその検証内容を発信しはじめた 8 月半ばには底入れし、イールドカーブ・コントロール（YCC）への政策変更（9 月 21 日）と同時期に改善した後、概ね横ばいとなっている。

ここで、ごく簡単に、YCC 導入（9 月 21 日）前後で、マイナス金利のイメージに有意な差があるかを検証した。具体的には、日次の「マイナス金利政策インデックス」の値を、YCC ダミー変数（9 月 21 日以降を 1 それ以前を 0）に回帰した。その結果、ダミー変数の係数は $+0.01$ で有意（ t 値：2.58）に正であることが確認された（切片=YCC 以前の平均水準は -0.03 ）。確かに YCC 導入後の「マイナス金利」へのイメージは、それ以前と比べて、平均的によりポジティブとなったことが確認された。

ちなみに、YCC 導入前の同インデックスが大幅にマイナスだった 2016 年 7 月 5 日から過去 30 日分のコーパスでは、「シュリンク」、「期待外れ」、「運用難」などの表現があり、関連語にネガティブな表現が多かったことがわかる。他方、同インデックスが改善した 2016 年 12 月 5 日から過去 30 日分のコーパスでは、「安堵」、「過去最高」、「有効」、「チャンス」などの表現がある（図表 6）。さらに、Word2Vec によって計算した「マイナス金利」と相関度順位の高い単語ランキング（相関順位 100 位以内で極性値 0 の語を除く）を、2016 年 7 月 5 日から過去 30 日分のコーパスと 2016 年 12 月 5 日から過去 30 日分のコーパスについて比較したのが図表 7 である。ここからも、2 つの期間について「マイナス金利」というキーワードと共に起しやすい単語のコロケーションが質的に変化していたことが確認される。

以上の極性値加重平均インデックスに加え、コーパスごとの「マイナス金利連想語」（相関上位 100 語）の極性値の加重標準偏差を用いて、「マイナス金利」に対するイメージのばらつきを測定したインデックスも作成した（図表 8）。計測された極性値のばらつきは期間平均で 0.063 程度であったが、2016 年の 5 月半ば～7 月半ば、8 月半ば～9 月初旬および 12 月後半については、明確にばらつきが大きかった。概ね、平均極性値のレベルシフトが起きる直前から同時期にばらつきが大きくなる傾向がある。実際、平均インデックスの前月差の絶対値と、標準偏差インデックスの時差相関係数を計算してみると、標準偏差インデックスの 1240 日ラグの値と平均インデックスの変化幅との相関が高いことが示された（図表 9）。あくまでも仮説ではあるが、あるテーマに関する評価極性の平均水準が変化する直前には、さまざまな意見が乱立してばらつきが大きくなり、その後、有力意見が再度集約されることで新しい平衡に達する、というメカニズムが考えられる。

（５）「マイナス金利政策インデックス」と市場長期金利

興味深いこととして、「マイナス金利政策インデックス」は 10 年物国債利回りとある程度連動していることがわかる（相関係数：0.30、図表 10）。つまり、マイナス金利政策は、長期金利が大きく低下した時点で問題視された（ネガティブなイメージを持たれた）が、長期金利が緩やかに上昇した後は、イメージが幾分改善している。すなわち、当座預金へのマイナス付利政策は変わっていないにもかかわらず、「マイナス金利政策」のイメージは改善した。このことは、日本銀行当座預金へのマイナス付利自体が問題視されたわけではなく、マイナス金利政策導入の後に長期金利が大きく低下したという事実が否定的に受け取られたことを示唆している。

この点は、日本銀行の「総括的検証」で示された見解とも整合的である。すなわち、「総括的検証」からは、日本銀行は、2016 年 7 月（Brexit 後）の大幅な長期金利の低下を背景としたマイナス金利政策へのイメージ悪化を経験し、金融機関等からの批判の原因が、量的緩和の拡大期待に伴う長めの金利の過度な低下にあると認識していることが窺われる。

日本銀行自身がマイナス金利政策の市場評価に対する認識を変化させた可能性は、日本銀行の公表文書のみを対象にして「マイナス金利」のイメージを計測した結果に表れている。すなわち、日本銀行が発表する文書における「マイナス金利」の自己評価は 2016 年 7 月まで平均的にポジティブであったが、8 月以降は一転しネガティブとなっている（図表 11）。実際、日本銀行は「総括的検証」の公表を予告した 2016 年 8 月以降、マイナス金利の副作用として、長期・超長期ゾーンの金利低下が家計や企業の金融システムの健全性に対する不安感へとつながり、実体経済に悪影響を及ぼし得る、との対外説明を行うようになっている。こうした変化がインデックスにも表れていると考えられる。

改めて確認すると、「マイナス金利政策インデックス」は、各時点でのコーパスにおける「マイナス金利」と相関の高い単語の極性値を集計したものである。コーパス内で「マイナス金利」と相関する（共に語られる）単語は、その時々々の景況・市場状況・金利状況など、さまざまな要因によって変化する。例えば、日本銀行が何も政策を変更しておらずとも、その情報発信の仕方や、実体経済の好不調、金融機関の収益状態、ひいては、為替レートや株価の水準などによって、マーケットやメディアは「マイナス金利」の功罪について語り方を変える可能性がある。そのため、同インデックスで捉えられる「マイナス金利のイメージ」は、さまざまな変数の影響が混濁したものである。言い換えれば、「マイナス金利」というキーワードが結果的にどのようなイメージを持たれているかを観測したものであり、日本銀行によるマイナス金利政策の運営についての評価だけを純粋に分析・抽出したものではない。

むしろ、さまざまな要因によって時々刻々と変化する「マイナス金利」というキーワードへのイメージをリアルタイムに捕捉できる点が、同インデックスの利点でもある。今後、十分にサンプルが蓄積されれば、同インデックスで記述的に数値化した「イメージ」が、どのような変数で説明され得るかを仮説的にモデル化し、検証することも可能になるとと思われる。

（６） 対照実験

白川・塩野〔2016〕での分析に加え、以上のように作成された「マイナス金利政策インデックス」への対照実験として、以下の 5 つの手法でインデックスを作成し、比較した。

- 1) 単純平均：「マイナス金利」連想語の極性値を、類似度によるウェイトを用いずに、単純平均してコーパス極性値を集計した。コーパスごとの「マイナス金利」とのコロケーション（共起性）の変化を提案手法よりも控えめに反映させることになる。
- 2) 全単語：Word2Vec で「マイナス金利」の関連語を抽出することをせず、コーパス内の全ての単語に辞書を適用し、単純平均でコーパス極性値を推計した。「マイナス金利」に関連した各コーパスに登場する極性語の得点平均であり、「マイナス金利」という単語の出現する文脈、コロケーションは無視している。
- 3) tf-idf：Word2Vec で「マイナス金利」の関連語を抽出することをせず、コーパス内の全ての単語に辞書を適用したうえで、tf-idf ウェイトによる加重平均でコーパス極性値を推計した。「マイナス金利」に関連した各コーパスにとって特徴的なキーワードの極性をより重く評価している。しかし、コーパス内での「マイナス金利」という単語の出現する文脈、コロケーションは無視している。
- 4) 長期金利：「マイナス金利」ではなく「長期金利」というキーワードについて提案手法と同じ手順で推計した。マイナス金利政策インデックスが長期金利との相関が高かったため、どの程度違いが出るかを検証した。
- 5) 国会・メディアのみ：提案手法では、市場参加者がテキスト情報を受け取ることで「マイナス金利」へのセンチメントを形成するプロセスを、アルゴリズム上で単純化して表現している。そのため、通常、市場で注目されている、日本銀行、政府、国会、メディア、からの情報ソースをまとめて扱った。しかし、マイナス金利政策へのセンチメントは、テキスト情報を通じてではなく、何らかの実益的なチャネルを通じて市場参加者や一般国民の間で一旦形成され、その形成されたセンチメントが国会・メディアを通じて抽出され、発信されている、という考え方もできる。その発想のもとでは、日本銀行・政府からの公表文書は、政策決定当事者による自己評価のようなものであり、政策を受け止める側が抱いたセンチメントを計測する対象にはならない。そ

のため、対照実験として、国会とメディアからの情報だけを用いたインデックスも作成した。

以上の結果を、提案手法による「マイナス金利政策インデックス」と比較すると、いずれの方法でも平均的にネガティブな値が示されたが、その動きについては差がみられた（図表 12）。なお、図による比較を容易にするため、指数の月次平均している。提案手法の時系列では、Brexit 後（17 年 7 月）のイメージ悪化とトランプ・ラリーに伴う回復（17 年 11 月）が特徴的であったが、1) の単純平均による方法では、それらの動きが明確ではなかった。また、2)、3) の Word2Vec による「マイナス金利」連想語の抽出を行わない方法についても、2016 年 5～6 月というマイナス金利への批判が強まったと認識されている時期にイメージが改善傾向にあった点や、トランプ・ラリーに応じて金利上昇が進み、運用難が和らぐとの安堵が広がった時期に反応していないなど、市場実感には沿わない動きがみられた。他方、4) の「長期金利」をキーワードにした方法では、2016 年 10 月までは提案手法とかなり似通った動きをしていた。マイナス金利政策へのイメージ悪化が長期金利との過度な低下に連動していたとの見方に整合的な結果である。つまり、2016 年 10 月以前は、「マイナス金利」は「長期金利」とほとんど同じ文脈で議論されてきたものと思われる。しかし、4) 「長期金利」のインデックスでは、2016 年 11 月のトランプ・ラリーに伴う評価値の急上昇と、その 2017 年 2 月以降の沈静化という動きはみられなかった。この期間には、「マイナス金利」という言葉のコロケーションとして、「長期金利」には関連しない話題が増えていたと考えられる。市場の全般的な期待感から影響を受けている可能性も考えられる。

最後に、5) 国会・メディアのみを情報源とした場合の結果は、一部に変動幅の違いが目立つものの、趨勢としては提案手法と似た動きとなった。提案手法と 5) のインデックスの差分は、日本銀行・政府の情報ソースに由来する成分であるが、2016 年 4～6 月にかけて提案手法が上回っていたものが、8 月以降は逆転する点などは、図表 11 のインデックスに示された日本銀行文書による寄与分があったと見て概ね整合的である⁵。なお、提案手法の情報ソースに含まれる出所別文書情報（単語数ベース）のシェアは、日本銀行：20%、政府：6%、国会：16%、メディア：58%となっており、量の上ではメディアが大半を占める（2016

⁵ もちろん、Word2Vec による意味ベクトルの推定過程は、ニューラルネットによる高度に非線形なものになっており、入力コーパスの足し引きに対して、出力であるインデックスの加法整合性は保証されない。

年 1 月 1 日～2017 年 3 月 8 日までの全データ）。そのため、提案手法と 5) のインデックスとで大きな差が出ていないこと自体は自然な結果である。

もとよりマイナス金利に対する「センチメント」または「イメージ」という観察できない概念を数値化しているため、これらのインデックス作成方法に客観的な優劣をつける方法が一般的に確立しているわけではなく、その選択は恣意的にならざるを得ない⁶。しかし、テキスト情報に触れた金融市場参加者が抱き得るマイナス金利政策へのセンチメントを数値的に記録するという目的にかんがみれば、Brexit とトランプ・ラリーという 2 つのイベントに伴うイメージの変動をよりよく反映していたという点で、提案手法が妥当であると思われる。

（７）「長短金利操作インデックス」の推計

さらに白川・塩野〔2016〕での分析に加えて、「マイナス金利政策インデックス」と同じ方法によって「長短金利操作」という単語に対するセンチメントを抽出した「長短金利操作インデックス」も作成した（図表 13）。計測期間は 2016 年 9 月 22 日から 2017 年 3 月 8 日までである。同指数の期間平均水準は 0.010 であり、「長短金利操作」のイメージは概ねポジティブなものとなっている。ポジティブ、ネガティブの各評価値を付されたテキストの実例を挙げると、図表 14 のようになっており、ポジティブ・イメージのテキストでは「強い緩和姿勢」、「うまく機能」、「確実性」などの表現が見られた一方、ネガティブ・イメージのテキストでは「敗れた」、「余儀なくされた」、「懸念」などの表現が見られた。

日本銀行によるマイナス金利政策から YCC への転換は、世間（主に金融機関を中心とした市場参加者）からのイメージという点では成功だったといえそうである。なお、インデックスの推移を見ると、日本銀行によるオペ運用の柔軟化などで国債市場がやや動揺した 2017 年 1～2 月初旬にはネガティブなイメージとなっていたが、その後は、日本銀行がオペ実施日の事前通知などコミュニケーションを強化する動きを受け、再びポジティブなイメージとなっている。

⁶ ヒューリスティックではあるが、潜在変数としての「センチメント」が観察可能な経済変数に影響を与えるものとし、また、その「センチメント」が計測誤差を伴って「マイナス金利政策インデックス」として観察されるという状態空間モデルを推定する方法なども考えられる。その場合、インデックスの作成方法ごとに赤池情報量規準（Akaike Information Criterion: AIC）などの情報量規準を比較し、どのインデックス作成方法を採用すべきかを判断することが考えられる。

3. 「物価ニュース・インデックス」の作成、推移と含意

白川・塩野〔2017a〕では、ニューラルネット型の AI を活用し、経済ニュース記事から、現在の物価動向を日次で推計（ナウキャスト）する「物価ニュース・インデックス」（「クレディ・スイス PNI」と呼称）を開発している。白川・塩野〔2017a〕では消費者物価（コア CPI）について計測しているが、同じ方法で企業物価や賃金について日次インデックスを作成することもできる。

具体的には、大量の物価関連ニュース記事からコア CPI 前月比の動きに関する特徴を抽出し、それによって回帰分析を行うよう AI を訓練した。訓練された AI に最新のニュース記事を外挿すれば、コア CPI 前月比の理論値が得られ、統計発表前に現在の CPI 動向を推定するナウキャストイングに利用できる。CPI の実績値は 2 ヶ月弱遅れて発表されるため、CPI の最新実績月（例えば 2017 年 1 月）までのデータを使って訓練した AI に、現在まで（2～3 月）のニュース記事を外挿すれば、まだ発表されていない足もと（2～3 月）の CPI をナウキャストすることができる。

（1）使用データ

本稿の AI モデルでは、物価関連ニュース記事を入力し、コア CPI 前月比にフィットさせる。入力側の記事データは、国内新聞 5 社（日経、読売、朝日、毎日、産経）のウェブサイトに掲載されたテキストから、Google Custom Search で「値上げ」、「値下げ」、「物価」、「価格」、「値段」、「賃金」、「給与」のいずれかを含む記事を検索した結果である。無償公開分を利用するため、記事のタイトルと冒頭のパラグラフが中心となっている⁷。なお、使用した物価関連ニュース記事の一部実例を図表 15 に示している。実例では、「値下げ」などの検索キーワードには関連するが、物価動向とは関係のなさそうなニュース（例、籠池氏問題）が取得されていることが見受けられる。なお、大規模なテキスト・データを扱う場合こうしたノイズが含まれることも多いが、こうした情報は CPI 変動の説明に役立たない限り AI を深層学習する過程で除去される⁸。

⁷ 文書をベクトルとして分散表現するには意味成分の分布が重要となるので、タイトルとサマリー部分でも十分だと考えられる。

⁸ 後述する Stacked denoising Autoencoder の過程で入力情報はより抽象度の高いカテゴリに統合されていくが、その際にノイズ的な情報は削ぎ落とされていく。

取得記事は日付ごとにまとめて日次のコーパス（文書群）とする。まず、外挿テストの段階では、日次コーパスを数値化したものを月中平均し、2013 年～2015 年分を訓練期間、2016 年 1 月～2017 年 1 月を外挿テスト期間として分析した。一方、被説明変数（出力側、教師データ）となる物価動向については、コア CPI（消費税除く）の季調済前月比を用いた。その後、ナウキャストイングのための逐次予測モデルでは、日次のコーパスを数値化したものを直接入力に用いており、月次データである出力側のコア CPI 季節済前期比に対しては、後述する Harvey [1989]で提案された Cumulator 変数法を応用してフィットさせている。

（２） AI の訓練手順

イ．テキストの数値化

まず、テキスト・データ（日次コーパス）を数値ベクトルに変換する。これには Doc2Vec という人工知能型のアルゴリズムを用いる（詳細は補論 2 を参照）。Doc2Vec は、1 つの文書（Document）を意味成分の分布を反映した 300 次元程度の実数値ベクトルとして表現する。2 節の「マイナス金利政策インデックス」の開発では、1 つの単語をベクトルで表現する Word2Vec というアルゴリズムを用いたが、Doc2Vec はその拡張版である。

ここでは、ニュース記事の日次コーパスを 1 つの入力文書として 300 次元の数値ベクトルに変換している。訓練と外挿テストに使用したデータの期間（2013 年 1 月 1 日～2017 年 1 月 31 日）は 1,492 日なので、1,492（時点）×300（変数）の時系列データが得られたことに等しい。また、月次平均を取って使う際には 49（時点）×300（変数）となる。

ロ．ニューラルネット（AI）の設計

続いて、コーパスから得た数値ベクトルを入力とし、コア CPI 前月比を出力とするニューラルネットを訓練する。この際、ニューラルネットの構造設計がモデル全体の性能を左右する。重要なのは、現実にはニュース記事が書かれ、物価統計が発表される際のプロセス（データ発生過程）を、適切に反映させたニューラルネットの構造にすることである。

今回の分析について、データ発生過程をフローチャートにすると、図表 16 のように表される。

すなわち、ある期間 t の物価関連ニュース記事 (Doc_t) には、さまざまな業種・商品の価格変更の情報が仕分けされずに含まれている（非構造データ）。こうしたニュース記事が生み出されるのは、それらの商品を生産する企業が価格変更を決めたからであるが、個別企業の価格決定プロセスは、収益環境やシェア競争など多様な相互作用のうえに成り立っている。そのため、詳細をモデルで明示しようとすれば切りがない。そうした背景要因は全て潜在変数群 (F_t) として大まかに定義しよう。つまり、 t 期のニュース記事は、多くの要因を含む潜在変数群のその時点での状態を反映して生成されたと捉える ($F_t \rightarrow Doc_t$)。

一方、モデルの出力データとなる消費者物価指数 (P_t) は、調査員がある時点 t で小売店の価格を調べた結果を集計したものである。したがって、ニュース記事を生成している背景（潜在変数群）のうち、目標であるマクロ消費者物価の変動 (dP_t) に直接関係するのは小売店の状況 (F_t^{retail}) だけである。しかし、それ以外の粗原材料や企業間商品（中間財、最終財）を生産する企業の動向やその他の経済環境 (F_t^{others}) が全く無関係なわけではない。当然ながら、小売店の収益・競争環境は、サプライ・チェーンのより川上にある企業の過去の価格決定などに左右されている。

すなわち、ある時点で記録される消費者物価の変動は、その時点の小売店の決定という潜在変数群の一部 (F_t^{retail}) を直接的に反映しているが、その潜在変数は、それ以外の潜在変数の過去の動向 ($F_{0:t-1}^{others}$) から影響を受けていると考えられる。したがって、ニューラルネットの設計には、こうした潜在変数群 ($F_t = [F_t^{retail}, F_t^{others}]$) の間の多変量自己回帰的な構造（動的ファクター）を反映させることが望ましい。言い換えれば、現在のニュースのうち、現在の消費者物価とは関係のない内容でも、サプライ・チェーンに沿って将来の変化に関係している可能性は考慮しておくべきであろう。

このようなデータ発生過程を重視し、文書ベクトルからの情報抽出に優れた SdA (Stacked denoising Autoencoder) と、潜在変数群の自己回帰（動的ファクター）を捉えるのに適した LSTM (Long-Short-Term Memory) を組み合わせたニューラルネットの構造を採用した（以下、SdA-LSTM と呼称、図表 17）。

なお、これらの技術的詳細は補論 2 で解説するが、SdA がさまざまな情報を同時に含むコーパス・ベクトルを深層学習してコア CPI 前月比の説明に役立つ特徴に分類し、そのうえで、LSTM が分類された潜在変数ごとに異なるコア CPI 前月比への影響の最適なラグ次数を内生的に決定するという点が技術的な勘所である。

ハ. ニューラルネット (AI) の訓練

実際のニューラルネットの訓練では、ベクトル化されたコーパスが逐次 SdA に入力されて特徴抽出され、その結果が LSTM の入力として渡される。LSTM の内部では自己回帰する潜在変数の状態が、新たな入力を受け取りつつ更新されており、每期、その潜在状態の現在値に基づきコア CPI 前月比の理論値が出力される。ニューラルネット (SdA と LSTM) 内部の各パラメータは、出力される理論値とコア CPI 前月比実績値との誤差を小さくするよう勾配降下法の一環である Adam (Adaptive moment estimation) によって推定される。

(3) 外挿テストとナウキャストイング

イ. 外挿テスト

訓練した AI モデル (SdA-LSTM) に、新しいニュース記事を入力すれば、コア CPI 前月比の外挿理論値が得られる。前述のとおり、モデルの外挿パフォーマンスを測るバックテストの段階では、2013 年 1 月～15 年 12 月のコア CPI 前月比のデータを用いて訓練し、2016 年 1 月～17 年 1 月までのデータで検証する。なお、ニュース・コーパスの数値ベクトルは、CPI の発表頻度に合わせて月次平均を取ってからニューラルネットに入力しており、理論値も月次ベースで算出される。

実際に、テスト期間におけるコア CPI 前月比の外挿理論値 (月次) と実績値の平均絶対誤差 (MAE) を様々なモデルについて計算した結果が図表 18 である。すなわち、提案モデルである SdA-LSTM 以外に、ネットワーク構成を SdA だけ、LSTM だけとしたモデルもテストした。また、ニュース・コーパスを数値ベクトル化する際の手法として、Doc2Vec を動的に用いる方法以外に、2 節で提案した外部データ (Wikipedia) を用いて事前に訓練を済ませた Word2Vec を用いる方法も検証した (詳しくは補論 2 (1))。なお、各モデルのメタ・パラメータ (潜在変数の次元数、SdA の付加ノイズ量、Adam の学習率など) については、複数の組合せを試して MAE が最小となった組合せを表示している (補論 2 (4))。なお、参照基準としてコア CPI 前月比を単純な 1 階自己回帰 AR(1) で外挿予想した場合の MAE も添えている。

最適化された各モデルの外挿結果について、内挿結果とともにプロットした図が図表 20 である。図表 18、19 からわかるように、提案手法 (SdA-LSTM) の結果が最も MAE が小さくなっており、その有効性が示されている。興味深いことに、ニューラルネットの構成について、SdA 単体での性能は AR(1) に劣って

いた。つまり、SdA だけではニュース記事から 1 期前のコア CPI 自身以上の情報を捉えることができなかった。他方、LSTM 単体の性能は AR(1)を超えており、ニュース記事の情報を上手く利用できていた。したがって、ニュース記事からコア CPI の動向を捉えるのに役立つ情報を引き出すには、潜在状態が自己回帰する構造（動的ファクター）が重要であることを示唆している。

SdA は深層学習を用いた表現力の高い分類器ではあるが、単体で用いた場合、ある時点のさまざまな内容を含んだニュース記事から、同時点のコア CPI 前月比に関係するものだけをフィルタし、その他の情報は捨ててしまう。他方、LSTM は単層の分類器であり表現力には乏しいが、過去のニュース内容がラグを伴って現在のコア CPI 前月比に影響するチャンネルを考慮している。やはり、2 節で説明したように、ニューラルネットの設計では、現実にはニュース記事が書かれ CPI が発表される際のデータ発生過程を適切に反映させた構造が重要だといえよう。提案手法である SdA-LSTM は、LSTM の分類器としての性能を SdA で高めた手法であり、期待どおり、最も高い性能を示した。

なお、コーパスのベクトル化に Doc2Vec ではなく Word2Vec (Wikipedia 事前学習) を用いた場合には、SdA-LSTM を用いても満足な性能が得られなかった。この点には議論の余地があるが、恐らく、Doc2Vec を動的に用いて物価関連ニュースという限られた語彙の中で意味成分を獲得したほうが、Wikipedia 日本語コーパスという膨大な語彙から意味成分を獲得するよりも効率的であったものと思われる。

ロ. ナウキャストिंगの性能

実際の業務として、この AI モデルをナウキャストिंगに利用するケースを考える。その場合、過去の 1 点までで訓練データを区切る必要はなく、毎月、最新の実績値を含めたデータで訓練し直すことが可能である（いわゆる、オンライン学習）。CPI の実績値は 2 ヶ月ほど遅れて発表されるため、CPI の最新実績月（例えば 1 月）までのデータを使って訓練した AI に、現在まで（例えば 2 ～3 月）のニュース記事を外挿すれば、まだ発表されていない足もと（2 ～3 月）の CPI をナウキャストすることができる。

さらに、これまではテスト用の簡便化としてニュース・コーパスの数値ベクトルを CPI の頻度に合わせて月次平均していたが、ナウキャストिंगでは即時性が大切であるため、日次コーパスの数値ベクトルをそのまま入力する方式を採る。この場合、コア CPI 前月比の理論値は入力に応じて毎日計算されるが、実績値が観察されるのは月に 1 回だけであるため、月末に実績値と日次理論値

の月間平均とを対応させることでフィッティングしている。具体的には、Harvey [1989]で提案された Cumulator 変数法を応用した手順で日次のモデル理論値 $\hat{y}_t$ と月次のコア CPI 前月比 y_t の実績値を対応させている。すなわち、月初から最新日 t までの累積平均値を C_t と定義し、以下の式に従って計算する。

$$C_t = \frac{(\xi_t C_{t-1} d_{t-1} + \hat{y}_t)}{d_t},$$

ただし、

$$\xi_t = \begin{cases} 0 & \text{if } t \text{ is the first day of a month} \\ 1 & \text{otherwise} \end{cases},$$

$$d_t = \begin{cases} 1 & \text{if } t \text{ is the first day of a month} \\ d_{t-1} + 1 & \text{otherwise} \end{cases}.$$

また、月次のコア CPI 前月比 y_t は各月末のみ実績値をデータとして持ち、その他の日付では欠損値とする。したがって、ニューラルネットのパラメータ学習のための損失関数は、欠損値ではない月末時点の y_t と、日次理論値 $\hat{y}_t$ の月末時点での累積平均値である C_t との2乗誤差を訓練期間について合計して評価される。

実際に、2016年1月～2017年1月までのテスト期間について、毎月 CPI 実績の発表に合わせて AI を再訓練しながら日次ニュース記事を入力し、コア CPI 前月比%の日次理論値を得た。これを「物価ニュース・インデックス」として記録していく。そのナウキャスト精度は良好である。テスト期間について「物価ニュース・インデックス」を事後的に月次平均し、コア CPI 前月比との平均絶対誤差 (MAE) を計算した結果、0.035%pt と AR(1)モデルの 0.066%pt と比べて高い精度が得られた。

また、追加的に、2017年2月～2017年9月までの期間についても逐次延長推計したところ、「物価ニュース・インデックス」のコア CPI 前月比に対する平均絶対誤差 (MAE) は、0.041%pt と引き続き良好な精度を保っていた (AR(1)モデル：0.048%pt)。なお、2016年1月～2017年9月までを通したバックテストの MAE は、同インデックスが 0.037、AR (1) が 0.059 であった。この「物価ニュース・インデックス」(AI 逐次訓練による理論値) を図示したのが図表 20 である。2016年1月以降が逐次外挿した正式な系列であり、2015年12月以前の値は便宜的に内挿推計値 (2013年1月～2017年1月の実績値で訓練) を表示している。

なお、同インデックスの値が計測期間の上位 1%にあった日と、下位 1%にあった日の物価関連ニュース記事のタイトルを図表 21 にまとめた。同表では、物価

上昇に関すると思われる内容の記事タイトルと物価下落に関する内容の記事タイトルとに著者が分類して掲載している。どちらとも言えない内容の記事タイトルを含めると大量になってしまうためそれらは掲載していない。なお、それぞれの該当日の全記事数に占める物価上昇関連記事のシェアから、物価下落関連記事のシェアを引いた DI を計算すると、PNI 値上位 1%の日付では+25% (30% -5%) とプラスであったのに対して、PNI 下位 1%の日付では-31% (40%-9%) と明確にマイナスであった。実際の LSTM による理論値（即ち PNI の値）は、モデルの内部状態に保持された過去のニュース記事からの影響を含んで算出されているため、同時点の入力記事だけで決まっているわけではない。PNI 上位 1%と下位 1%に対応する同時点の記事だけからも、人手で物価上昇関連記事のシェアから物価下落関連記事のシェアを差し引いて得た DI に対応するように記事内容の差が明確に現れていた。また、実際の記事タイトルからは、食品価格や電気料金、モバイル料金など、過去数年の CPI 変動の鍵となった品目に関する価格変更のニュースが確かに捕捉されていた点がわかる。以上のことから、「物価ニュース・インデックス」は、深層学習の結果、物価上昇に寄与する価格変更ニュースをプラス寄与とし、その逆をマイナス寄与とするような構造を確かに獲得したと言える。なお、比較的小売段階に近く CPI に直接的に反映される品目の価格変更記事が目立ったが、こうした傾向は、インデックス値（上位 1%、下位 1%の時点）と記事の日付を同時点で対応させ選んだため当然である。

なお、「物価ニュース・インデックス」を月次平均して実績と比較したのが図表 22、また、この月次平均の理論値（コア CPI 前月比）を用いてコア CPI の水準を求め、前年比に変換した場合の理論値を計算したものが図表 23 である。図表 23 からみてもわかるとおり、コア CPI 前年比インフレ率へのナウキャスト性能は良好であり、2016 年 1 月～2017 年 9 月までのテスト期間では、平均絶対誤差が 0.039%pt であった。同期間のブルームバーグ・コンセンサス調査によるエコノミスト予想（中央値）は、平均絶対誤差が 0.043%pt であり、「物価ニュース・インデックス」は市場予想よりもやや高いパフォーマンスを示した。このように、日々のニュース記事情報を上手く活用することで、高いパフォーマンスの CPI 予想を日次のリアルタイムで行うことができる。

4. おわりに

本稿では、人工知能技術（AI）とテキスト・データを活用して作成された「マイナス金利政策インデックス」（白川・塩野 [2016]）と「物価ニュース・インデックス」（白川・塩野 [2017a]）を紹介するとともに、新たに「長短金利

操作インデックス」を構築・推計し、それらのインデックスの有用性についてさまざまな対照実験を行うことで検証を行った。

「マイナス金利政策インデックス」と「長短金利操作インデックス」の構築を通じて確認されたことは、マイナス金利政策に関する文書に反映されたセンチメントは、同政策導入当初から悪化傾向を続け、Brexit 後の 2016 年 7 月初旬に大底となった。その後は、日本銀行による「総括的検証」や「長短金利操作」導入に伴う長期金利の上昇に伴って、ネガティブ度合いは緩和された。こうした動きは長期金利とほぼ連動しており、「マイナス金利への批判は、当座預金へのマイナス付利そのものではなく、長めの金利の過度な低下による金融機関の収益悪化懸念が背景である」という日本銀行の「総括的検証」の認識とも整合している。もっとも、その後は、2016 年 11 月からのトランプ・ラリーとその沈静化に連動する局面もみられ、「マイナス金利」という言葉のコロケーションが市場の全般的な期待感からも影響を受けている可能性が示唆された。このように、さまざまな要因に左右された「マイナス金利」というキーワードに対するイメージの変動をリアルタイムに捕捉できる点が、同インデックスの利点でもある。さらに、コーパスごとの極性値のばらつき測定したインデックスは、平均インデックスの前月差に対して幾分先行性がみられた。仮説としては、「マイナス金利」に関する極性評価の平均水準が変化する直前に、さまざまな意見が乱立してばらつきが大きくなり、その後、有力な意見に集約されていくという遷移パターンが考えられる。

「物価ニュース・インデックス」の構築を通じて確認されたことは、物価関連ニュース記事のように完全には分類されていない非構造のテキスト・データからでも、AI（ニューラルネット）型のモデルを活用することによって、設定した目的に適う情報を引き出せるということである。今回は消費者物価の動向（コア CPI 前月比）のナウキャストिंगを目的としたが、同じ方法を企業物価や賃金について用いることもできる。なお、モデルの被説明変数（教師データ）に前月比を用いることで高い精度が得られているが、ニュース記事から得られる情報には直前からの変化に関する事項が多いと考えられ、その点において前月比の説明に適していたものと考えられる。

「マイナス金利インデックス」と「物価ニュース・インデックス」の構築に際して、使用したデータ量や計算時間などの計算環境は図表 24 のようにまとめられる。使用している月単位当たりのテキスト量に大きな差はないものの、後者についてはやや複雑なアルゴリズムとなり、前者よりは計算時間を要する。もっとも、両者とも一般的な計算機環境で数分以内には計算することができ、日次更新し実務的に分析に利用していくことができる。

「マイナス金利政策インデックス」と「長短金利操作インデックス」については、今後、時系列データの蓄積が進めば、さまざまな計量経済学分析に活用することが可能になるほか、さまざまな拡張が考えられる。例えば、構造的な方向性としては、金融政策効果の波及経路を実証的に分析する構造多変量自己回帰（SVAR）モデルにおける内生変数の1つとして同インデックスを含め、市場での金融政策についてのセンチメント・ショックと他の変数の応答を識別するという利用方法が考えられる。また、テキスト情報を通じて観察できない潜在変数としてのセンチメントが形成され、それが金融市場での価格形成などに影響を与える波及経路について、状態空間モデルなどを用いてモデル化することなども考えられる。一方、ヒューリスティックな拡張の方向性としては、SNSなどのビッグデータを入力データに取り込み、金融市場参加者に限らず社会一般におけるセンチメントを測ることも考えられる。また、今回のインデックス作成方法は文脈における意味が特定されていれば多様なキーワードについて適応可能であるため、その都度注目度の高い政策についてのインデックスを作成することも考えられる。こうした拡張は今後の課題である。また、「物価ニュース・インデックス」については、利用するニュースの特性を活かして、前年比インフレ率を被説明変数とする場合には、ニューラルネットの出力層にある線形変換に、1期前のインフレ率、GDPギャップ、輸入物価インフレ率等の外生変数を加え、ハイブリッド型フィリップス・カーブを念頭に置いたモデルに拡張することも考えられる。その場合、AIは、外生変数では説明し切れない前年比インフレ率の変動（主にフォーワード・ルッキングなインフレ期待およびショック項の寄与）に対応する情報をニュース記事から抽出するように訓練される。このような経済理論を事前知識として援用したAI構造のモデリングは今後の課題である。

補論 1. Word2Vec を用いたテキスト・マイニング

(1) 形態素分析

日本語でのテキスト・マイニングには、まず、文書を単語ごとに区切られた「分かち書き」にする必要がある。また、登場頻度が多いものの単独で意味を持たない助詞や記号などの品詞を除く処理も必要となる。こうした処理を「形態素分析」と呼ぶが、これを行うには MeCab というフリー・ソフトウェアが利用できる。

本レポートの 2 つの分析では共に、MeCab を使って文書を分かち書きにしたうえで、「名詞」、「動詞」、「形容詞」、「形容動詞」のみを抽出している。

(2) 1-of-K 表現

続いて、「分かち書きテキスト（品詞抽出済）」を数値で表現する方法として「1-of-K 表現」を用いる。1-of-K 表現とは、ある要素だけが 1 で、それ以外が 0 な K 次元のベクトルである。分かち書きテキストに含まれる単語を重複なしで集めた「単語リスト」を用意し、その単語数を K とする。そして、それぞれの単語を一つの 1-of-K ベクトルに対応させる。これによって、分かち書きテキストは、その単語総数が N 、重複なし単語数が K だとすれば、 $N \times K$ 次元のビット (1 or 0) 行列として表現される。

(3) 変換行列 W の学習

Word2Vec は、文書中のそれぞれの単語を、文脈（文中でその単語の前後に出現する単語）を考慮しながら、200～300 次元程度のベクトルに変換する。この時、ベクトルの基底（座標軸）は独立した意味成分を代表しており、1 つの単語は 200～300 個の意味成分の組合せとして分散表現される。このようにして、単語の大まかな意味を捉えることができる。

具体的には、文書中での各単語（語彙）の出現を表す 1 of K ベクトル（図表 A-1）を、300 次元程度の実数ベクトルに変換するための変換行列 W ($K \times 300$ 次元) を得る必要がある。その際、Word2Vec では、文書中の単語の並び（＝文脈: word[t], word[t+1], word[t+2]）を入力（説明変数）として、それに続く単語（word[t+3]）を出力（被説明変数）として予想するようなニューラルネットを学習することで変換行列 W を推定する（図表 A-2）。

同アルゴリズムは、米 Google 社の研究者 Tomas Mikolov 氏らによって開発され、無償で公開されている (Mikolov *et al.* [2013])。

(4) 単語の演算

Word2Vec によって変換された単語ベクトルが得られれば、単語間の加算・減算や類似度 (相関) の計算が可能となる。例えば、十分な量の日本語テキストを学習した Word2Vec は、以下のような演算に正確に答えることが知られている。

Q 「フランス」 - 「パリ」 + 「東京」 = 類似度の高い単語は？

A 「日本」

また、弊社が日本銀行の公表文書のみを用いて Word2Vec を学習した際には、図表 A-3 のような興味深い演算結果が得られた。

なお、2 節での分析は、全てプログラミング言語の Python を使って行っており、特に、Word2vec のアルゴリズムは、自然言語処理を行う Python ライブラリである Gensim を用いて実装している。

補論 2. 物価ニュース・インデックス作成の AI 技術

(1) Doc2Vec

「物価ニュース・インデックス」の作成においては、テキスト・データ（日次コーパス）を数値ベクトルに変換してからニューラルネットに入力している。その方法としては、Doc2Vec という AI 型のアルゴリズムを用いている。

Doc2Vec は、1 つの文書（Document）を、意味成分の分布を反映した 300 次元程度の実数値ベクトルとして表現する（分散表現と呼ばれる）。1 つの単語をベクトルで表現する Word2Vec というアルゴリズムは「マイナス金利政策インデックス」の開発に用いたが、Doc2Vec はその拡張版である。

Doc2Vec は Word2Vec と同様のニューラルネットの学習の際、ある単語が出現する文脈の一部として文書 ID を同時に含める拡張である。つまり、学習データである文書群に含まれる個別文書に ID を付し、変換行列 W を推定する際の説明変数として、文書中の単語の並びにその文書 ID を含め、後続の単語を予想するようなニューラルネットを学習する（図表 A-4）。この文書 ID は、回帰分析におけるダミー変数のような役割を果たしている。

以上のように、Doc2Vec を用いれば、学習データの文書群に含まれる個別文書を数値ベクトルに変換することができる。3 節の分析では、この学習文書群を観測日 t から 60 日前まで（過去約 2 ヶ月分）の日次ニュース・コーパスの集まりとし、毎日ローリングさせて、観測日のコーパスを動的にベクトル化している（図表 A-5）。学習を外部コーパスによらず、一定の文書量を確保しながら、かつ、将来の情報を用いずに、ベクトル化することが狙いである。

また「物価ニュース・インデックス」の開発では、ニュース・コーパスを数値ベクトル化する際の手法として、Doc2Vec を用いる方法以外に、外部データ（Wikipedia コーパス）を用いて事前に訓練を済ませた Word2Vec を用いる方法も試している。この場合、個別の日次コーパスに含まれる各単語を全て個別に学習済みの Word2Vec でベクトル化し、平均することでコーパスごとのベクトルとしている（図表 A-6）。

(2) Stacked denoising Autoencoder (SdA、積層雑音自己符号化器)

SdA (Stacked denoising Autoencoder) は深層学習（ディープラーニング）を用いた表現力の高い分類器である。一般的に、多段に積層されたニューラルネット（Deep Neural Network、以下、DNN、図表 A-7）のパラメータを推定する（＝

学習する)ことを深層学習と呼ぶ。通常 DNN では、入力層が外部からのデータ (x) を受け取り線形変換 (W^1, b^1) した後、隠れ層 (中間層) を経由するが、この際にシグモイド関数などの非線形変換 (ϕ) が施される。隠れ層からの出力は再度、線形変換 (W^2, b^2) されて出力層に入り、適宜変換 (g) されて被説明変数の理論値 (y) を出力する。DNN の最も単純な推定方法は、計量経済学における多変量非線形回帰モデルと同様、入力データ (説明変数) と出力データ (被説明変数、教師データ) を用意し、初期値をランダムに与えたうえで、勾配降下法などの最適化アルゴリズムで誤差を最小化するパラメータを推定するものである。しかし、この場合、推定値がパラメータ空間のローカルミニマムな点に留まってしまうことが多く、性能に限界があった。

そこで、SdA の枠組みでは、入力そのものを出力とする「自己符号化」を用いて事前学習 (プレトレーニング) を行う。この作業によって DNN の内部パラメータの初期値を整えてから、本番の推定 (ファインチューニング) を行う (図表 A-8)。こうした 2 段階推定をすることで、推定値がパラメータ空間のグローバルミニマムに到達しやすくなる。さらに、SdA では、推定に使用したデータへの過学習 (オーバーフィッティング) を避けるために、事前学習の段階でノイズを付加し、汎化性能 (外挿予想のパフォーマンス) を高める工夫をしている。

張・小町 [2015] では、日本語文章の評価極性 (ポジティブ／ネガティブ) 分類タスクにおいて、文書の分散表現を入力データとして用いた SdA 分類器が、辞書や係り受けなどの素性エンジニアリングを行う方法よりも高い精度を得たと報告している。ニュース記事から意味成分を抽出し、コア CPI の変動を説明するという「物価ニュース・インデックス」の構築においても精度向上に寄与することが期待される。

(3) Long-Short-Term Memory (LSTM)

LSTM (Long-Short-Term Memory) は、隠れ層 (中間層) が自己回帰する構造を持った再帰的ニューラルネット (Recurrent Neural Network、以下、RNN) の拡張である。RNN や LSTM の内部では自己回帰する潜在変数 (f) の状態が、新たな入力 (x) を受け取りつつ更新されており、每期、その潜在状態の現在値に基づき理論値 (y) が出力される。こうした構造は、潜在変数群が自己回帰するという意味で、計量経済学 (時系列分析) におけるダイナミック・ファクター・モデルに近いといえる。

通常の RNN では、隠れ層（潜在変数）の自己回帰性は 1 期ラグのみであるが、LSTM では、隠れ層が出力データへ影響するのにかかる最適なラグ次数を内生的に決定することができる。すなわち、原理的には、入力初期（0 期）から直前（ $t - 1$ 期）までの全ての隠れ層の情報を必要に応じて保持する仕組みが、メモリーブロックと呼ばれる機構によって実装されている（図表 A-9）。メモリーブロックは、自己ループを持ったコアと 3 つのゲート機構（入力ゲート、忘却ゲート、出力ゲート）からなっている。コア（ c_t ）は自らの現在状態を出力して次期の入力とするサイクルを続けている。途中で他のゲートによる介入がない限り同じ情報を永久に持ち続ける記憶装置である。入力、忘却、出力の各ゲート（ i_t 、 g_t 、 o_t ）は、外部からの新しい入力データ（ x_t ）とメモリーブロックからの前期の出力（ f_{t-1} ）を受け取り、それらの情報をコアで保持するか否か（入力ゲート）、どの程度の期間保持するか（忘却ゲート）、また、いつ読み出すか（出力ゲート）を、訓練データへのフィットが最適になるように適応させていく。

（４） SdA-LSTM のパラメータ推定

「物価ニュース・インデックス」の作成では、LSTM の入力として SdA の出力を用いたネットワーク構造を採用している（SdA-LSTM と呼称）。LSTM は単層構造でありそれ自体の表現力は高くないため、SdA と組み合わせることでその点を強化している。この SdA-LSTM に含まれる内部パラメータは、出力される理論値とコア CPI 前月比実績値との誤差を小さくするよう勾配降下法の一環である Adam（Adaptive moment estimation）によって推定している。

その他の設定としては、LSTM の出力層は線形で 1 次元（コア CPI 前月比のみ）の回帰モデルとしている。SdA の積層数は 3 層で固定、Adam の学習率はデフォルト設定（ $\alpha=0.01$ 、 $\beta_1=0.9$ 、 $\beta_2=0.999$ ）で固定しているが、その他のメタ・パラメータ（SdA 隠れ層の次元数、LSTM 隠れ層の次元数、SdA の付加ノイズ量）は複数の組合せで外挿テストを行い、MAE が最小となるものを選んでいる（図表 A-10）。

なお、LSTM と SdA の実装と Adam によるパラメータ推定には Python の Chainer というライブラリを用いた。

参考文献

- 和泉潔・後藤卓・松井藤五郎、「テキスト分析による金融取引の実評価」、『人工知能学会論文誌』第 26 巻第 2 号、2011 年、313～317 頁
- 荻原 廣、「日本人の語彙量（理解語彙、使用語彙）調査を行うにあたっての基礎的研究」、『京都語文』21 号、2014 年、1～30 頁
- 片倉賢治・高橋大志、「金融市場ニュースの分散表現学習による辞書作成と金融市場分析」第 29 回人工知能学会全国大会論文集 2G5-OS-25b-5、2015 年
- 小林のぞみ・乾健太郎・松本裕治・立石健二・福島俊一、「意見抽出のための評価表現の収集」、『自然言語処理』第 12 巻第 3 号、2005 年、203～222 頁
- 塩野剛志、「文書の分散表現と深層学習を用いた日銀政策変更の予想」第 16 回人工知能学会金融情報研究会資料、SIG-FIN-016-11、2016 年
- 白川浩道・塩野剛志、「マイナス金利政策インデックスを開発」、『クレディ・スイス日本経済分析』第 70 号、2016 年
- ・———、「クレディ・スイス物価ニュースインデックス（PNI）を開発」、『クレディ・スイス日本経済分析』第 75 号、2017 年 a
- ・———、「テキスト・データの数値化—「マイナス金利政策インデックス」を開発—」、『統計』2017 年 4 月号、2017 年 b、15～21 頁
- 高杉亮介・山名早人、「国会議事録を用いた経済指標のナウキャストイング」、『日本データベース学会和文論文誌』第 14-J 巻第 9 号、2016 年
- 張培楠・小町守、「単語分散表現を用いた多層 Denoising Auto-Encoder による評価極性分類」、第 222 回自然言語処理研究会、2015 年
- 東山昌彦・乾健太郎・松本裕治、「述語の選択選好性に着目した名詞評価極性の獲得」、『言語処理学会第 14 回年次大会論文集』、2008 年、584～587 頁
- 吉原輝・藤川和樹・関和広・上原邦昭、「深層学習による経済指標動向推定」第 28 回人工知能学会全国大会論文集 3H3-OS-24a-5、2014 年
- Baker, Scott R., Nicholas Bloom, and Steven J. Davis, “Measuring Economic Policy Uncertainty,” *Quarterly Journal of Economics*, 131(4), 2016, pp.1593–1636.
- Balke, Nathan S., Michael Fulmer, and Ren Zhang, “Incorporating the Beige Book into a Quantitative Index of Economic Activity,” *Journal of Forecasting*, 36(5), 2017, pp.497–514.
- Harvey, Andrew C., *Forecasting, Structural Time Series Models and the Kalman Filter*, Cambridge University Press, 1989.

Mikolov, Tomas, Ilya Sutskever, Kai Chen, Greg Corrado, and Jeffrey Dean, “Distributed Representations of Words and Phrases and their Compositionality,” *Advances in Neural Information Processing Systems*, 26, 2013, pp.3111–3119.


Shibamoto, Masahiko, “Empirical Assessment of the Impact of Monetary Policy Communication on the Financial Market,” RIEB Discussion Paper Series No.DP2016-19, Kobe University, 2016.

Shiller, Robert J., “Narrative Economics,” Cowles Foundation Discussion Paper No.2069, Yale University, 2017.

Thorsrud, Leif Anders, “Words are the New Numbers: A Newsy Coincident Index of Business Cycles,” Norges Bank Research Working Paper No.21/2016, 2016.

図表

図表 1 「マイナス金利政策インデックス」の作成に用いる日次コーパス




資料：クレディ・スイス

図表 2 「マイナス金利」連想語の一例

連想語	相 関	連想語	相 関
1 タイムラグ	0.64	11 サプライズ	0.57
2 踏み切っ	0.61	12 質的	0.57
3 無限	0.59	13 経過	0.57
4 効力	0.58	14 相殺	0.57
5 度合い	0.57	15 止める	0.57
6 浸透	0.57	16 当たっ	0.56
7 経路	0.57	17 失望	0.56
8 打ち止め	0.57	18 余計	0.56
9 狙い	0.57	19 量的緩和	0.56
10 怒り	0.57	20 副作用	0.56

資料：内閣府、日本銀行、日本経済新聞、トムソン・ロイター・データストリーム、ブルームバーク、クレディ・スイス

図表 3 コーパス極性値の計算手順




資料：クレディ・スイス

図表 4 東北大辞書に所蔵された単語評価極性の例

単語	極性値
効力	+1
打ち止め	-1
怒り	-1
失望	-1
余計	-1
副作用	-1

資料：クレディ・スイス

図表 5 「マイナス金利政策インデックス」



資料：内閣府、日本銀行、日本経済新聞、トムソン・ロイター・データストリーム、ブルームバーグ、クレディ・スイス

図表 6 「マイナス金利」に関する評価値を付されたテキストの実例

(各日付の過去30日間の累積コーパスから抜粋)	
ポジティブ評価：2016年12月5日、インデックスの値： +0.05	ネガティブ評価：2016年7月5日、インデックスの値： -0.10
「不動産融資7兆円 16年度上半期、マイナス金利で増加： 日銀は16日、銀行や信用金庫の不動産業向けの新規融資額が、2016年度4～9月期に前年同期比14.7%増の7兆706億円に達したと公表した。上半期としては2年連続で過去最高を更新した。日銀が1月に導入を決めたマイナス金利政策で金融機関の貸出金利が低下し、不動産業者の借り入れが増加した。」(2016年11月16日付日本経済新聞電子版)	「企業はマイナス金利を入れるほど景気が悪いのかと思ってしまう、景気を良くするどころか、どんどん企業経営者の気持ちをシュリンクさせている」(2016年6月6日付ブルームバーグ)
「日銀総裁、国債買い入れとマイナス金利「たいへん有効」：日本経済新聞 日銀の黒田東彦総裁は22日午前の参院財政金融委員会で、大量の国債買い入れ(公開市場操作)とマイナス金利の組み合わせについて『イールドカーブ全体に影響を与えうるうえでたいへん有効』(2016年11月22日付日本経済新聞電子版)	「量的緩和と超低金利は、今もまだ当初の約束を果たせていない。マイナス金利の効果は、さらに期待外れで終わっている。先進国の経済成長はあいかわらずバツとせず、各国中央銀行の当局者は、しつこいデフレに頭を抱えている。こうした状況下、金融実験室が生み出す次の作品が、いわゆる「ヘリコプターマネー」であっても不思議はない。」(2016年6月4日付ロイター)
『「マイナス金利環境下は、ある意味でチャンス。顧客の9割が預金しか持っておらず、資産形成にシフトする必要がある」と述べ、今後、資産運用ビジネスを強化していく方針を示した。』(2016年12月5日付ロイター)	「三菱UFJの国債特別資格返上、決断の背後にマイナス金利... (中略)... マイナス金利政策をめぐって、同行は『(銀行にとって)明らかにネガティブ』(三菱UFJフィナンシャル・グループの平野信行社長)との立場を崩していない」(2016年6月8日付ロイター)


資料：内閣府、日本銀行、日本経済新聞、トムソン・ロイター・データストリーム、ブルームバーグ、クレディ・スイス

図表 7 「マイナス金利」と相関の高い単語ランキング (相関順位 100 位以内で極性値 0 の語を除く)

(各日付の過去30日間の累積コーパス)					
ポジティブ評価：2016年12月5日、インデックスの値： +0.05			ネガティブ評価：2016年7月5日、インデックスの値： -0.10		
極性値	Cos類似度	単語	極性値	Cos類似度	単語
1	0.43	安堵	-1	0.36	ショック
1	0.41	ヒント	1	0.36	自由度
-1	0.39	少なく	-1	0.34	凍りつい
-1	0.39	限界	-1	0.33	否定
1	0.39	的中	-1	0.32	外す
1	0.38	先駆け	-1	0.32	悪夢
-1	0.35	否定	-1	0.30	過大
1	0.33	有利	-1	0.29	苦悩
1	0.33	確信	1	0.27	有力
-1	0.32	ペナルティー	-1	0.27	妨げ
1	0.32	増やせ			
1	0.32	合格			
1	0.32	補完			
-1	0.31	徴収			


資料：内閣府、日本銀行、日本経済新聞、トムソン・ロイター・データストリーム、ブルームバーグ、クレディ・スイス

図表 8 加重標準偏差を測定したインデックス




資料：内閣府、日本銀行、日本経済新聞、トムソン・ロイター・データストリーム、ブルームバーグ、クレディ・スイス

図表 9 平均指数の前月差絶対値[t]と標準偏差指数[t+s]の時差相関係数




資料：内閣府、日本銀行、日本経済新聞、トムソン・ロイター・データストリーム、ブルームバーグ、クレディ・スイス

図表 10 「マイナス金利政策インデックス」と 10 年物国債利回り




資料：内閣府、日本銀行、日本経済新聞、トムソン・ロイター・データストリーム、ブルームバーグ、クレディ・スイス

図表 11 日本銀行文書における「マイナス金利」への評価




資料：日本銀行、クレディ・スイス

図表 12 提案手法と対照実験手法の比較（月次平均）



資料：内閣府、日本銀行、日本経済新聞、トムソン・ロイター・データストリーム、ブルームバーグ、クレディ・スイス

図表 13 「長短金利操作インデックス」



資料：内閣府、日本銀行、日本経済新聞、トムソン・ロイター・データストリーム、ブルームバーグ、クレディ・スイス

図表 14 「長短金利操作」に関する評価値を付されたテキストの実例

(各日付の過去30日間の累積コーパスから抜粋)	
ポジティブ評価：2016年11月29日、インデックスの値：+0.06	ネガティブ評価：2017年1月5日、インデックスの値：-0.04
「国債を無制限に買い入れる指し値オペ(公開市場操作)を金融機関に初めて通知した。9月に導入した金融緩和の新枠組みの柱である長短金利操作の一環。トランプ米次期大統領の経済政策を巡り米国債利回りが急上昇し、日本の債券市場にも波及。日銀は日本国債利回りの上昇傾向をけん制し、強い緩和姿勢を示す狙いがある」(2016年11月17日付日本経済新聞電子版)	「元審議委員の中原伸之氏は9月のインタビューで、「レジームを量から金利に変えたということ自体、日銀内でリフレ派が敗れたということだ」と指摘。リフレ派の岩田副総裁、原田泰、桜井真両審議委員が反対しなかったことに疑問を呈していた」(2016年10月3日付ブルームバーグ)
「『主な意見』を公表した。9月の金融政策決定会合で導入した長短金利操作(イールドカーブ・コントロール)について『金利の変動はごく限られた範囲内にとどまり、枠組みはうまく機能している』との意見があった。」(2016年11月9日付ロイター)	「長短金利操作政策の導入以降、初めて国債購入額を増額。16日にも国債買い取りを実施するという異例の『オペ予告』にも踏み切った。世界的に金利の上昇圧力が強まるなか、市場との攻防が本格化している」(2016年12月15日付日本経済新聞電子版)
「今回の円安をもたらした日米金利差の拡大は「日銀のイールドカーブ・コントロールによって確実性が高まった」と分析。」(2016年11月21日付ブルームバーグ)	「『主な意見』では、長短金利操作に否定的な見方も複数あった。ある委員は『指し値オペの実施を早期に余儀なくされたことは、長短金利操作の難しさを裏付けた。国債買い入れを伴わない指し値オペは、実効性が低い』と指摘。さらに『超長期国債の買い入れ増額措置は、長短金利操作の下では国債買い入れのベースが高まるリスクが相応に高いという当初からの自身の懸念を裏付けるものである』と述べた。」(2016年12月29日付ブルームバーグ)


資料：内閣府、日本銀行、日本経済新聞、トムソン・ロイター・データストリーム、ブルームバーグ、クレディ・スイス

図表 15 使用する物価関連ニュース記事の例

タイトルのみ、2017年3月23日から抜粋			
タイトル	出所	タイトル	出所
ゴム急騰、悩むタイヤメーカー 値上げに迷いも	日経	名古屋市周辺、タクシー7%値上げ 4月21日から	朝日
東京ドーム、「大人の」ボウリング場	日経	日清、家庭用油22商品値上げ	朝日
SUMCO、「11年ぶりの春」は続くか	日経	王子ネピア、ティッシュなど1割以上値上げへ...5月から	毎日
宇部興産、ナイロン樹脂を値上げ 4月から1割前後	日経	大手電力10社、5月料金上げ 都市ガス4社も	毎日
三菱ケミHDが小動き アクリル樹脂原料を値上げ	日経	名古屋のタクシー、4月に運賃改定 初乗り430円からに値下げもメーター加算は割高に	産経
ヤマトの運賃引き上げ、8割が「賛成」	日経	「格安スマホ」もっと安く 携帯大手3社が接続料10~20%引き下げへ	産経
エスビー10年ぶり 小袋スパイスで個食とらえる	日経	松山の下水道料 据え置き	読売
近畿の住宅地、上昇地点広がらず 郊外の戸建てなど需要鈍く	日経	籠池氏「首相夫人から百万円」、政府側は否定	読売


資料：総務省、日本経済新聞、読売新聞、朝日新聞、毎日新聞、産経新聞、クレディ・スイス

図表 16 物価ニュースとコア CPI 前月比のデータ発生過程



資料：クレディ・スイス

図表 17 使用する AI モデル（SdA-LSTM）の概念図




資料：クレディ・スイス

図表 18 外挿テストの結果比較

ベクトル化	モデル	MAE
Doc2Vec	SdA-LSTM	0.055
Doc2Vec	LSTM	0.060
Doc2Vec	SdA	0.075
Wikipedia	SdA-LSTM	0.071
-	AR(1)	0.066


資料：総務省、日本経済新聞、読売新聞、朝日新聞、毎日新聞、産経新聞、クレディ・スイス

図表 19 外挿テストの結果比較（時系列グラフ）



資料：総務省、日本経済新聞、読売新聞、朝日新聞、毎日新聞、産経新聞、クレディ・スイス

図表 20 「物価ニュース・インデックス」 (PNI)



備考：PNI については、日次で集計した数値をプロットしている。

資料：総務省、日本経済新聞、読売新聞、朝日新聞、毎日新聞、産経新聞、クレディ・スイス


図表 21 「物価ニュース・インデックス」の値が上位 1%と下位 1%となった日の物価
関連ニュース記事のタイトル

上位1% 上昇要因	出所	下位1% 上昇要因	出所
1 加工用米の価格据え置き提示 全農、生産者の収入優先	日経	1 菜種、7カ月半ぶり高値 国際価格 大豆・パーム油も強含み	日経
2 負担増今からチェックを	産経	2 メルセデス日本、車両価格を平均2%値上げ 6月から	日経
3 清水建設、15年ぶりベア 業績好調で1万円	日経	3 ニッケ、学生向けニット製品6%値上げ 原料・人件費高で	日経
4 永谷園、お茶漬けなど25年ぶり値上げ 7月から5～10%	日経	4 明治と森永乳業、4月に乳製品値上げ	日経
5 日銀の量的緩和 揺るがず脱デフレ果たせ	産経	5 時給5000円の求人も 派遣技術者の争奪戦が過熱	日経
6 デンソーとアイシン、期間従業員の賃金上げ	日経	6 発電用木材の価格上昇 再生エネで需要拡大	日経
7 牛丼価格、大手3社300円台に 低価格争い下火	日経	7 ネスレ日本、即席コーヒー値上げ 17～21%	日経
8 すき家、賭けの値上げ 深夜再開へ「原資」確保	日経		
9 食料品の値上げに対抗するならコメを食べよう！	朝日		
10 円安の時代に突入？ 外貨を持たないリスクとは	朝日		
11 メタノール、国際価格が一段高 東南アで供給不安	日経		
12 …菓子・玩具・保険…「大人の」商品なぜ広がる	日経		
13 電気・ガス料金、全社が値上げへ	朝日		
14 昭和産業、2017年2月1日出荷分から油脂製品の価格を値上げ	毎日		
15 ガソリン価格、130円台に値上がり 1年1カ月ぶり	朝日		
16 通関高くなる！ 大人の入場料が17年半ぶり値上げへ	産経		
17 ベンツ日本、ディーゼル11モデルに拡大	産経		
18 ゼンショーがパート・バイトの時給を一律2.5%引き上げ	産経		
19 ATM手数料、初の値上げへ 日本郵政が消費税増で転嫁	産経		
20 ユニクロ再値上げ、7月以降新商品の2割 平均10%	日経		
21 ガソリン、13カ月ぶり130円台乗せ 店頭価格	日経		
22 信越化学やSUMCO、半導体ウエハー値上げ 11年ぶり	日経		
23 来年2月の電気・ガス料金	毎日		
24 食品値上げ、際どい交渉 どの小売りを優先？	日経		
下落要因		下落要因	
1 穀物の国際価格、在庫増で値下がり 大豆は半年ぶり安値	日経	1 米原油輸出解禁、価格を下押し、日本、調達先の分散期待	毎日
2 構造用鋼、2年半ぶり下落 流通価格	日経	2 スマホ料金の引き下げは競争促進で	日経
3 車保険、若者向け安く 三井住友海上は1割	日経	3 ユニクロ再値上げ、7月以降新商品の2割 平均10%	日経
4 マックスバリュ九州、低価格店を倍増 2年で30店に	日経	4 関電高浜原発、29日にも再稼働 川内に続き2カ所目	日経
		5 ダイヤモンド値下がり 国際価格5年ぶり安値	日経
		6 日銀決定会合・追加緩和、判断に注目 物価目標先送り検討	毎日
		7 関電4月に値下げ、家庭で5%前後 高浜原発再稼働で	日経
		8 物価上昇の秘策！？「日銀版消費者物価」検討	日経
		9 春闘：スタート 賃上げの広がりに焦点 労使、ベアへの姿勢後退	毎日
		10 東京ディズニーが期間限定で500円安い平日用パスポート発売	産経
		11 燃油サーチャージ、国内発券もゼロに 4月から	産経
		12 ドコモ：最安3000円下げ 春商戦、低額プラン各社投入	毎日
		13 シャープ労組、統一交渉から4年連続離脱 ベア要求見送り	日経
		14 ドコモ「家族割」拡充 携帯値下げ、そろり始動	日経
		15 九電に比べ3%安く 西部ガス、電気料金発表	日経
		16 物価上昇の減速「価格据え置き」の呪縛」存在	日経
		17 電力会社、どう選ぶ？ 小売りの全面自由化	日経
		18 16春闘スタート 底上げに向けた交渉を	毎日
		19 バンコクポスト天然ゴム、続く価格下落	日経
		20 グリコ、ご当地ポッキー刷新 味改良し価格下げ	日経
		21 関電「値下げ」明言 関西中小、コスト削減に期待	産経
		22 ガソリン価格下落、100円割れも 家計には恩恵	産経
		23 チリ産ワイン：輸入増 低価格と味、人気 首位の仏を抜く勢い	毎日
		24 鉄鋼大手、業績悪化に拍車 バスコ、初の最終赤字	日経
		25 物価上昇の減速「価格据え置き」の呪縛」存在	日経
		26 国産ナフサが13%安 15年10～12月、6年半ぶり安値	日経
		27 中部電力：首都圏向けの新料金発表	毎日
		28 「自撮り」ドローンも活躍 価格破壊で建設現場に浸透	日経
		29 再生エネ、太陽光に北風 買い取り価格を3年連続下げ	日経
		30 廃ペットボトル価格大幅下落、上期6割安 原油安で	日経
		31 太陽光、3年連続下げで事業用30円割る	産経
		32 NTT東西、光回線の同一料金足かせに	産経

備考：物価上昇に関すると思われる内容と物価下落に関する内容とに著者が分類。どちらとも言えない内容は掲載としていない。


資料：日本経済新聞、読売新聞、朝日新聞、毎日新聞、産経新聞、クレディ・スイス

図表 22 「物価ニュース・インデックス」(PNI、月次平均)



資料：総務省、日本経済新聞、読売新聞、朝日新聞、毎日新聞、産経新聞、クレディ・スイス

図表 23 「物価ニュース・インデックス」(PNI、月次平均)を基に計算したコア CPI 前年比の理論値



資料：クレディ・スイス

図表 24 「マイナス金利インデックス」と「物価ニュース・インデックス」の計算環境

	マイナス金利政策 インデックス	物価ニュース インデックス
計測期間	2016/1～2017/3	2013/1～2017/1
テキスト文字数	3,449,024	10,759,410
（1ヵ月当たり）	229,935	224,154
同バイト数	0.69GB	2.41GB
（1ヵ月当たり）	(46.0MB)	(50.2MB)
更新頻度	日次	日次
基幹AI技術	Word2Vec	Doc2Vec + SdA + LSTM
計算時間	28秒	352秒
（秒／1日更新）		
プロセッサ	Intel Core-i7 3.6GHz	
メモリ	RAM 16GB	
実装言語	Python2.7; Chainer 1.2	

資料：クレディ・スイス


補論図表

図表 A-1 文書中での各単語（語彙）の 1-of-K ベクトル表現

		Unique Word list of X, (D)						
		わが国	景気	輸出	生産	...	D _K	
Document, (X)	わが国	=	(1,	0,	0,	0,	...	0)
	景気	=	(0,	1,	0,	0,	...	0)
	輸出	=	(0,	0,	1,	0,	...	0)
	生産	=	(0,	0,	0,	1,	...	0)
	.	.	.	.	.	.	.	.
	.	.	.	.	.	.	.	.
	.	.	.	.	.	.	.	.
	X _N	=	(0,	0,	0,	0,	0,	0)

資料：クレディ・スイス

図表 A-2 Word2Vec の仕組み




図表 A-3 単語演算による関連語リストの推計結果


単語・演算		関連語		
		1位	2位	3位
景気	⇒	経済 (0.41)	自律 (0.40)	基調 (0.39)
黒田－緩和	⇒	白川 (0.53)	次期 (0.47)	就任 (0.46)
異次元－黒田＋白川	⇒	包括 (0.62)	追加 (0.59)	派遣 (0.46)
インフレ＋期待	⇒	アンカー (0.36)	潜在 (0.33)	技術革新 (0.30)
インフレ－物価＋景気	⇒	逆効果 (0.33)	示唆 (0.31)	下降 (0.30)
バブル＋崩壊	⇒	後遺症 (0.58)	生成 (0.56)	未曾有 (0.43)
財政－緊縮	⇒	発展 (0.43)	提起 (0.34)	高齢者 (0.31)

資料：日本銀行、クレディ・スイス

図表 A-4 Doc2Vec の仕組み




図表 A-5 Doc2Vec を動的に用いた文書のベクトル化




資料：クレディ・スイス

図表 A-6 事前に Wikipedia で学習した Word2Vec を用いた文書のベクトル化




資料：クレディ・スイス

図表 A-7 多層ニューラルネット（DNN）の概念図




資料：クレディ・スイス

図表 A-8 SdA の概念図



資料：クレディ・スイス

図表 A-9 RNN と LSTM の概念図



資料：クレディ・スイス

図表 A-10 外挿テストにおけるモデルごとのメタ・パラメータ選択

ベクトル化	モデル	SdA 隠れ層数	LSTM 隠れ層数	SdA入力データ破棄率
Doc2Vec	SdA-LSTM	200	200	20%
Doc2Vec	LSTM	—	50	—
Doc2Vec	SdA	100	—	5%
Wikipedia	SdA-LSTM	100	100	10%
—	AR(1)	—	—	—