

# 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

## Forecast System for the BoJ's Monetary Policy Change by Distributed Representation of Documents and Deep Belief Network

塩野 剛志<sup>1\*</sup>

Takashi Shiono<sup>1</sup>

<sup>1</sup> クレディ・スイス証券株式会社 経済調査部

<sup>1</sup> Economic Research, Credit Suisse Securities (Japan) Limited

**Abstract:** The author utilized text-mining and deep-learning technics to forecast a monetary policy change by the BoJ. More specifically, the classifier of the BoJ's documents was developed, which picks up the document containing any trait of previously-experienced precursor for monetary policy change. Such classifier was constructed by obtaining distributed representation of documents via Doc2Vec and feeding them into Deep Belief Network with economic time-series data. The back-test for the period from Jan 2014 to Jan 2016 showed a fair performance of the classifier to send precursory signals against two cases of additional monetary easing.

### 1. はじめに

日本銀行による金融政策の変更は、金融市場における重大な関心事のひとつである。特に 2013 年 4 月の黒田総裁就任以降、その注目度は更に高まっている。異次元規模の資産購入（2013 年 4 月）とその拡大（2014 年 10 月）、更にはマイナス金利の導入（2016 年 1 月）と、金融市場の価格形成を歪めるほどの大掛かりな政策変更が行われたためだ。

黒田総裁体制の日本銀行は、金融政策の変更を市場が十分に予期しないまま行うため、市場参加者からサプライズ志向と看做されている。こうした方針は、政策変更のインパクトを強める一方で、市場が予想する政策の方向性が安定せず、様々な市場価格のボラティリティを高める一因となっている可能性がある。換言すれば、日銀の公表する文書や総裁の発言を、言葉通り解釈しているだけでは、日銀がいつ何をするつもりなのか予期できない、という不確実性のコストが生じている。

したがって、もし従来通りの人間による文書読解では見落とししてしまうようなパターンが、まだ日銀の政策変更に残されているならば、それを何らかの手法を用いて捕捉することで、市場機能の安定化にある程度寄与できるだろう。

そのようなパターンを抽出する手法として、近年、

画像認識等での高い実績が注目されている深層学習の技術を試すことは有益だと思われる。

深層学習の手法は、金融市場分析でも少なからず応用が進んでいる。例えば、[1] Chao, et al.は、深層信念ネットワーク（DBN: Deep Belief Network）を為替レートの予想に用いた研究だが、連続値をとる時系列データに深層学習の手法を用いた初期の例として注目されている。また、[2] 小牧・白山は、同様の手法に改良を加え、日経平均株価の予想に用いている。

他方で、テキスト・データによる機械学習（自然言語処理）を金融市場分析に用いた研究も盛んである。例えば、[3] 和泉 他は、日銀の金融経済月報から共起解析・主成分分析・回帰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した。また、[4] 吉原 他は、金融市場関連のニュースを深層学習モデルの一種である RNN-RBM（Recurrent Neural Networks Restricted Boltzmann Machine）に読み込ませ、株価の予想に応用した。また、[5] 片倉・高橋は、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。

これらの先行研究は、深層学習の応用やテキスト・データの活用が金融市場分析に対しても総じて有用であることを示している。一方で、いずれの研究も、その目的は市場価格の変動を予想することが主であり、金融政策の変更を直接に扱うことは一般

\* 連絡先：クレディ・スイス証券株式会社 経済調査部、〒106-6024 東京都港区六本木 1-6-1 泉ガーデンタワー26 階、Takashi.shiono@credit-suisse.com

的でない。

こうした背景から、本稿では、日銀の政策決定変更のパターンを、日銀が公表する文書を用いた深層学習によって抽出し、政策変更の予想に役立てることを新たに試みる。

## 2. 分析手法

日銀が公表した文書を、政策変更直前の特徴を有する (1) か否 (0) かに分類する。すなわち、[6] Le and Mikolov によって提案された文章の分散表現を獲得する手法と、深層信念ネットワーク (deep belief network; DBN) を組み合わせ、新たに入力された日銀の文書が、次回の決定会合で金融政策の変更を行った過去ケースと同様の特徴を有するか否か、判別するための分類器を学習する。その際に、テキスト・データだけでなく、マクロ経済状態を表す時系列データを組み合わせて用いる。

### 2.1 Doc2Vec による文章分散表現の獲得

[6] Le and Mikolov は、単語だけでなく単語が属する文章の分散表現 (文章ベクトル) を獲得する手法を提案している。Doc2Vec はその手法を実装したモジュールである。

単語の分散表現 (単語ベクトル) を獲得する手法としては、[7] Mikorov, et al. で提案された CBOW (Continuous-Bag-of-Words) と Skip-gram の精度が高いことが知られ、近年注目を集めている。これらの実装は Word2Vec というモジュールとして公開されているが<sup>2</sup>、Doc2Vec はその拡張版という位置付けである<sup>3</sup>。

Doc2Vec のデフォルト手法である Distributed Memory Model of Paragraph Vectors (PV-DM) は、単語のまとまりである文章 (Paragraph) に ID を付し、その ID を単語と同じベクトル空間に配置する (文章ベクトルを構成)。この際、文章ベクトルは、設定した文脈窓に後続する単語をより正確に予想できるように学習される。この仕組みを示したのが次図 1 である。すなわち、文脈  $w(t)$ ,  $w(t+1)$ ,  $w(t+2)$  とそれらが属する文章の ID を入力とし、後続の単語  $w(t+3)$  を出力としたニューラル・ネットワークを、トレーニング・データの文章全域にわたって学習することで、単語と文章の分散表現が得られる。

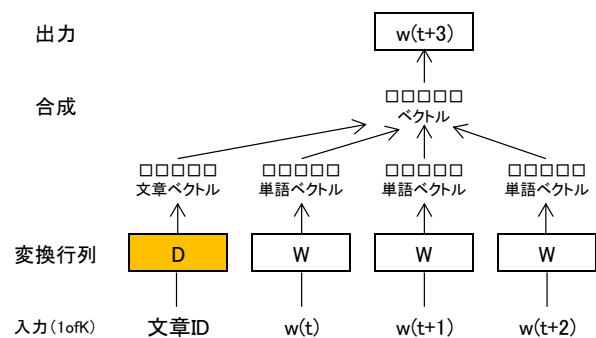


図 1: PV-DM の概略図

### 2.2 DBN を用いた分類器の学習

続いて、Doc2Vec によって獲得した文章ベクトルを、経済時系列データと合わせて分類器の入力として利用する。

本稿では、線形分類器 (ロジスティック回帰) の内部を、CRBM (Continuous Restricted Boltzmann Machine) で多層化した深層信念ネットワーク (DBN) を用いる。CRBM は [8] Chen, et al. によって提案され、経済時系列データなどの連続値を扱えるように RBM (Restricted Boltzmann Machine) を修正したものである。

この CRBM を積層し、出力層をロジスティック回帰 (LR) とした深層信念ネットワークを、一般的な深層学習のプロトコルに倣って、プレトレーニングした後、誤差逆伝播法によってファインチューンし、学習を行う。同様の手法は、為替レートの予想を行った [1] Chao, et al. や日経平均株価の予想を行った [2] 小牧・白山などに見られる。

本稿では、(1) 経済時系列データをまとめたベクトルとテキスト・データから作成した文章ベクトルを、共に多層 CRBM に入力して使用するケースと、

(2) 多層 CRBM には文章ベクトルだけを入力し、経済データ・ベクトルは最後のロジスティック回帰の層に直接入力するケースを推計する。また、比較対象として (3) DBN を用いずに、文章ベクトルと経済データ・ベクトルを共にロジスティック回帰に直接入力したケースも試している。

これらの 3 つのモデル (図 2) について、日銀の政策変更予想のパフォーマンスを比較していく。

<sup>2</sup> <https://code.google.com/p/word2vec/>

<sup>3</sup> なお、本稿では Doc2Vec の Python 実装である Gensim パッケージを用いている。

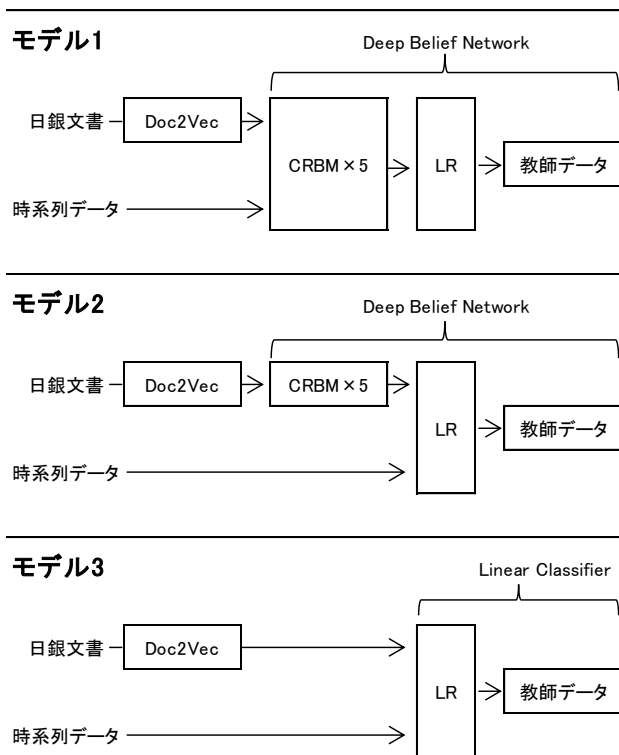


図 2: モデル全体の概略図

### 3. 使用データとパラメータ設定

使用したテキスト・データは、日本銀行がウェブサイト上に公開<sup>4</sup>している 2011 年 1 月～2016 年 1 月までの決定会合声明文、金融経済月報、展望レポート、総裁記者会見記録である。

通常、テキスト・マイニングでは、助詞や記号などは出現頻度が高く、かつ、単独で意味を持たないため除去することが多い。今回の分析でも、形態素分析を行い、名詞、動詞、形容詞、形容動詞、のみを用いている。

一方、経済時系列データについては、日銀が政策変更の判断に際して、特に重視していると思われる 5 変数を用いる。すなわち、(1) CPI 前年比の 10% 刈込平均値、(2) CPI (除く生鮮食品) 前年比、(3) CPI 前年比の加重中央値、(4) 日経平均株価の前年比、(5) ドル円レートの前年比である。

ロジスティック回帰の被説明変数となる教師データは、それぞれの文書について、その発表日から見て次回に当たる決定会合で政策変更が決められた場合には 1、そうでなければ 0 としたダミー変数である (以下、政策変更直前ダミーと呼ぶ)。

このとき、教師データと文書データのサンプル数

はマッチしているが、経済時系列データはそうではない。ドル円レートと日経平均については日次データがあるため文書発表日の終値を使用する。また、月次データである CPI については、文書発表日の時点で発表済みの直近値を使用する。

以上のデータセットを、2011 年 1 月～2013 年 12 月までをトレーニング・データとし、2014 年 1 月～2016 年 1 月までをテスト・データとして分割して用いる。

トレーニング・データを用いたモデル学習とテスト・データによる検証の手順をまとめると以下の通りである。

- (1) トレーニング用の文書データを Doc2Vec に入力し、各文書の分散表現を獲得する。この時、分散表現のベクトル次元は 200 とし、文脈窓は 10 語に設定した。
- (2) 文書ベクトルと経済データ・ベクトルを入力とし、政策変更直前ダミーを教師データとした DBN を学習する。このとき、CRBM の積層数は 5 層であり、隠れ層の次元は深くなるにつれて 150、125、100、75、50 と小さくしている。
- (3) テスト用の文書データを Doc2Vec に追加し、文書の分散表現を学習し直す。こうした手順は、実際の運用において文書の発表毎に Doc2Vec モデルを更新することを念頭にしている。
- (4) (3) で得られたテスト期間の文書ベクトルと経済データを、(2) で学習された DBN に入力し、政策変更直前ダミーの外挿理論値を得る。
- (5) この政策変更直前ダミーの理論値と実績値を比較し、モデルを評価する。

### 4. 分析結果

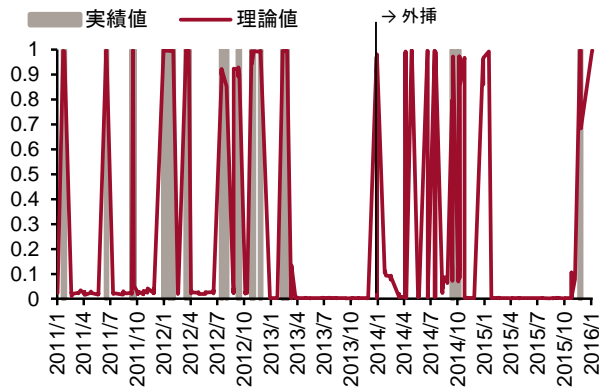
テスト期間である 2014 年 1 月～2016 年 1 月の間に、日銀による明確な政策変更は、2 度行われた。具体的には、2014 年 10 月 31 日の量的質的緩和の拡大と 2016 年 1 月 29 日のマイナス金利の導入である。

それぞれのモデルが、これらの決定日の直前に公表された文章についてどれだけ明確なシグナルを出すかがパフォーマンス評価のポイントとなる。


推計された 3 つのモデルによる政策変更直前ダミーの外挿理論値を、その実績値と比較したのが図 3 である。テスト期間の平均絶対誤差を計算すると、モデル 1 が 22.9%、モデル 2 が 9.4%、モデル 3 が 39.9% となった。

<sup>4</sup> <http://www.boj.or.jp/>

モデル1



モデル2



モデル3

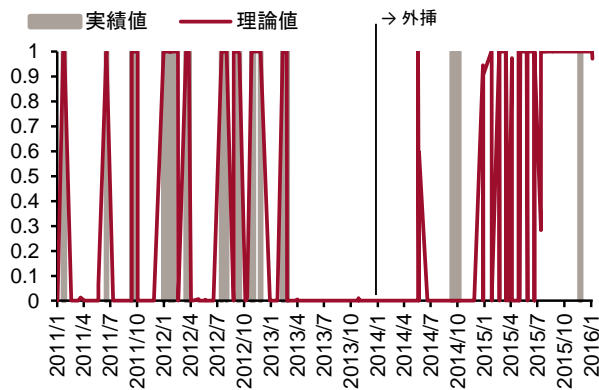


図3：政策変更直前ダミーの実績値と理論値

すなわち、テスト期間の平均的なパフォーマンスとしては、モデル2のパフォーマンスが高かった。もともと、図表3から分かるように、モデル2は2016年1月の政策変更前に明確なシグナルを発していたが一方で、2014年10月の政策変更に対しては無反応であった。

他方、モデル1は、2014年10月の政策変更の前後に不要なシグナルを出したために精度が悪いが、2014年10月と2016年1月の両方の政策変更に対し反応を見せていた。

以上のことから、モデル1とモデル2を相補的に

参照することで、過去2回の政策変更の気配を察知できた可能性がある。

なお、モデル3はいずれの緩和にも有用なシグナルを発したとは言い難い。つまり、深層学習を行うことで、単純なロジスティック回帰に比べて予測パフォーマンスが向上していることを確認できた。

## 5. まとめ

本稿では、日銀による過去の金融政策変更のパターンを、日銀が公表する文書を用いた深層学習によって抽出し、政策変更の予想に役立てることを試みた。

具体的には、Doc2Vecによって文章の分散表現を獲得し、それを時系列データと組み合わせて深層信念ネットワーク(DBN)に学習させることで、新たに入力された日銀の文書が、次回の決定会で金融政策の変更を行った過去ケースの特徴を有するか否か、判別するための分類器を開発した。推定された分類器は、バック・テストの結果、過去2回(2014年10月と2016年1月)の金融政策変更に対して、ある程度有用なシグナルを発していたと言える。

一方、本稿の分析には更なる精度改善の余地が大いにある。用いるデータの種類や、テキスト・データと経済時系列データを同時に扱う際の工夫などによって、予想精度が大きく変わる。

また、より本質的には、日銀の政策変更行動をより構造的にモデル化すべきだろう。つまり、日銀が経済情勢を観察し、政策変更の必要性を評価し、文書を作成して市場に伝達し、政策決定会で合意を図るまでの一連のプロセスを、潜在変数を含んだデータ生成モデルとして備えることが理想である。

## 参考文献

- [1] Chao, J., Shen, F. & Zhao, J.: Forecasting exchange rate with deep belief networks. 2011 International Joint Conference on neural Networks (IJCNN), pp. 1259-1266, (2011)
- [2] 小牧 昇平, 白山 晋: Deep Belief Networkを用いた日経平均株価の予想に関する研究, 人口知能学会研究会資料, SIG-FIN-012-08, (2014)
- [3] 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, 第24回人工知能学会全国大会論文集, 3H1-OS12a-2, (2010)
- [4] 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)
- [5] 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)

- [ 6 ] Le, Q., & Mikolov, T.: Distributed representations of sentences and documents. arXiv preprint arXiv:1405.4053v2. , (2014)
- [ 7 ] Mikolov, T., Chen, K., Corrado, G., & Dean, J.: Efficient estimation of word representations in vector space. arXiv preprint arXiv:1301.3781. , (2013)
- [ 8 ] Chen, H., & Murray, A.F.: Continuous restricted Boltzmann machine with an implementable training algorithm. Vision, Image and Signal Processing, Vol. 150, No. 3, pp. 153-158, (2003)