

機械学習を用いた国債イールドカーブの 変動モデルの構築と長期金利予測

Fluctuation model of JGB yield curve
using machine learning and the interest rate prediction

水門善之^{1,2}

Yoshiyuki Suimon^{1,2}

¹ 野村証券株式会社 金融経済研究所

¹ Nomura Financial and Economic Research Center

² 東京大学大学院 工学系研究科

² Graduate School of Engineering, The University of Tokyo

Abstract: In this research, I have developed a prediction model of long-term interest rate (long-term government bond yield) using machine learning method (SVM, nonlinear SVM, decision tree, RF, logistic regression, LSTM). As a result, it was confirmed that the accuracy of the LSTM-based model is relatively higher in the long-term interest rate prediction than the other models. Furthermore, long-term interest rate is influenced by interest rate fluctuations in the surrounding maturity due to the influence of arbitrage transactions. Therefore, I constructed a fluctuation model of the yield curve incorporating the relationship between long-term interest rate and the other maturity rates in the form of extending the above-mentioned LSTM-based prediction model. As a result, when using the yield curve fluctuation model for predicting long-term interest rate, some improvement was seen in the prediction accuracy of long-term interest rate.

はじめに

長期金利とは、人々の経済活動の活況度合いを映し出す代表的な指標であり、経済の体温計とも呼ばれる。一般に、長期金利は長期国債（10年利付国債）の利回りを指すことが多い。国債の市場価格は、様々な需給要因の影響を受けつつ、マクロ経済環境の変化を織り込む形で、日々形成されていく。そして、長期国債の価格から求まる利回り（長期金利）もそれに伴って変化していく。本研究では、このような長期金利を対象として、各種機械学習手法を用いた先行き予測精度の検証を行った。特に、近年、深層学習を用いた機械学習手法が注目されている点を踏まえ、本研究では時系列分析への有用性が知られる LSTM (Long Short Term Memory) [1]を用いた予測モデルの作成を行い、他の機械学習手法 (SVM, 非線形 SVM, 決定木, RF, ロジスティック回帰, k近傍法) に基づく予測モデルとの、先行き予測精度の比較を行った。結果、LSTM ベースのモデルにおいて、長期金利の相対的な予測精度の高さが確認できた。

更に、長期国債は周辺年限の国債との裁定取引の

影響等から、周辺年限の金利変動の影響を受けやすいという金融市場の特性を踏まえ、本研究では、前述した LSTM ベースの予測モデルを拡張する形で、長期金利と他年限金利の関係（金利の期間構造）を考慮したイールドカーブの変動モデルの構築を行った。結果、金利の期間構造を考慮した予測モデルを用いた場合、長期金利の予測精度に改善の傾向が見られた。このことは、長期国債の価格形成に影響を与え得る国債の年限間の相対価値 (Relative Value) の情報が、長期金利予測において有用な情報となることを示唆する結果と言えよう。

長期金利と国債イールドカーブ

長期金利（長期国債の利回り）は、マクロ経済環境を表す代表的指標である。一般に、経済活動が活発な時は、家計の消費や企業の設備投資等が積極的に行われることから、家計や企業が高い金利を支払ってでも資金を調達したいという需要が高まり、結果、銀行貸出や社債、国債等の金利に上昇圧力がかかる。また、国債や社債等の金利は発行体である国や企業のクレジットリスクの影響も受ける。例えば、

発行体の財務・財政状況に対する不安が高まると、資金調達コストの上昇という形で、金利に上昇圧力がかかる。他にも、名目ベースの長期金利はインフレの影響も受ける。例えば、人々のインフレ期待が上昇すると名目金利も上昇するという関係は、フィッシャー方程式として知られる。このように、様々なマクロ経済環境の変化を織り込みながら、市場で取引される長期国債の価格は形成され、そこから計算される利回り（長期金利）も日々変化していく。




図 1: 日本の長期金利の推移

本研究では、長期金利として日本の 10 年国債の利回りを扱う。長期金利の推移は図表 1 に示した通りである。他にも、日本では 2 年、5 年、10 年、20 年、30 年、40 年の利付国債が発行されており、幅広い年限の市場金利が存在している。それらの金利をつなぎ合わせた曲線はイールドカーブと呼ばれる (図 2)。




図 2: 日本国債のイールドカーブ

国債は年限によって市場参加者が異なることから、年限によってその変動特性も異なる。例えば、短期金利は、一般に中央銀行の金利操作目標の影響を直接的に受けることから変動性は乏しい。一方で中長

期金利は、市場の価格形成メカニズムが働く環境下においては、マクロ経済環境の変化等を織り込みながら変動する。また、長期国債の先物に連動する 7 年付近の金利はヘッジファンド等のアクティブな投資家の影響が表れやすく、当該年限がイールドカーブ全体の動きを主導する場面も見受けられる。

機械学習を用いた長期金利予測

これらを踏まえ、以下では長期金利を対象として、各種機械学習手法を用いた先行き予測の検証を行う。近年、深層学習 (Deep Learning) を用いた様々な金融経済分析が行われており、その応用範囲は多岐に渡っている。中でも、リカレントニューラルネットワーク (RNN) の一種である、LSTM (Long Short Term Memory) [1] は時系列分析での有用性が知られており、株価予測への応用 [2] なども行われている。

本節では、LSTM の長期金利予測での有効性を検証するため、他の代表的な機械学習手法である、SVM (サポートベクターマシン)、非線形 SVM (非線形サポートベクターマシン、Gaussian カーネル使用)、決定木、RF (ランダムフォレスト)、ロジスティック回帰、 k 近傍法に基づく予測モデルとの比較を行った。分析に使用したのは 1992 年 7 月から 2018 年 6 月までの 10 年日本国債利回りの週次変化のデータ [3] である。

具体的には、過去 3 週間の利回りの変化に対して、先行き 1 週間の利回りの変化を教師ラベルとし、モデルの学習を行った (図 3)。SVM、決定木、RF、ロジスティック回帰、 k 近傍法については、教師ラベルを金利の上昇か低下の二値とした。また、LSTM の場合は、先行き 1 週間の金利変化を教師ラベルとし、予測値に基づいて上昇か低下の判別を行った。




図 3: 学習データ

本研究で用いたプログラミング言語は Python であり、各機械学習手法は scikit-learn 及び、TensorFlow をバックエンドとした Keras を用いて実装した。なお、本研究で実装した LSTM モデルの構造は次節で詳解する。

本研究では、対象期間のデータに対し、ランダムに抽出した 8 割を訓練データとしてモデルの学習を

行い、残り2割のテストデータを対象として学習済みモデルの予測精度の検証を行った。更に、同様の方法で4種類のテストデータを作成し、それらを用いてモデルの予測精度の検証を行った。各種モデル別の長期金利の上昇・低下の方向性予測の正答率は図7に掲載した通りである(図中の「LSTM(期間構造導入)」は次節での提案手法)。これによると、他の手法に基づく予測モデルに比べ、LSTMベースの予測モデルにおいて、長期金利予測の相対的な精度の高さが確認できる。

イールドカーブの変動モデルの構築

前節までは長期金利の単一時系列の変動情報に基づいて先行き予測を行ってきた。しかし実際の長期金利は、国債の年限間の相対価値(Relative Value)に基づいて変化する需要と供給のバランスや、周辺年限の国債との金利差に着目した裁定取引の存在等、様々な投資家行動の影響を受ける。この点を踏まえ、本研究では、前述したLSTMベースの予測モデルを拡張する形で、長期金利と他年限金利の関係(金利の期間構造)を考慮したイールドカーブの変動モデルの構築を行った。

LSTMとはリカレント(再帰)な特性を持つニューラルネットワークであり、入力層と出力層の間にある隠れ層が、再帰的なネットワークとして結合されているものである。LSTMが通常のリカレントニューラルネットワーク(RNN)と異なる点は、隠れ層における各ユニットが、LSTMブロックと呼ばれる構造をしている点である。なお、本研究で用いたモデルでは隠れ層のユニット数は100としている。




図4: LSTMモデルの説明

分析に使用したデータは前節同様、1992年7月から2018年6月までの日本国債利回りの週次データ[3]である。前節での長期金利の予測モデルでは、学習に用いた入力データ x_t は10年利回りの変化のみであったが、ここでは、図5に示す通り、5年、10年、20年の金利変化及び、それぞれの年限の相対的

な金利差という5次元のベクトルを入力データ x_t として設定する。そして、これらの過去3週間の変化に対して、先行き1週間の変化の情報を教師ラベルとして、モデルの学習を行う。

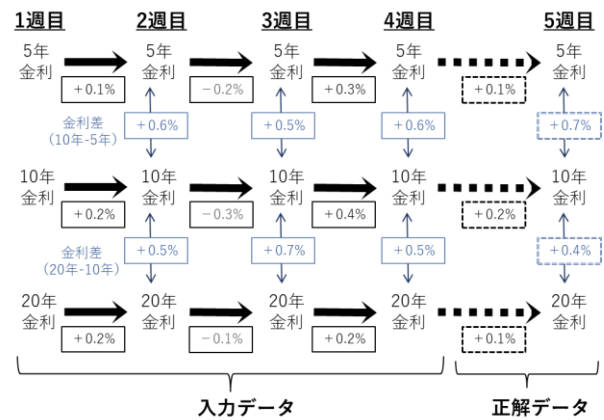


図5: 拡張モデルの学習データ

このようなイールドカーブの形状変化を表現するため、本モデルの入力層 x_t と出力層 y_t のデータとして、以下のベクトルを設定する。

$$x_t = \begin{pmatrix} r_t^{20} - r_{t-1}^{20} \\ r_t^{20} - r_t^{10} \\ r_t^{10} - r_{t-1}^{10} \\ r_t^{10} - r_t^5 \\ r_t^5 - r_{t-1}^5 \end{pmatrix}, y_t = \begin{pmatrix} r_{t+1}^{20} - r_t^{20} \\ r_{t+1}^{20} - r_{t+1}^{10} \\ r_{t+1}^{10} - r_t^{10} \\ r_{t+1}^{10} - r_t^5 \\ r_{t+1}^5 - r_t^5 \end{pmatrix}$$

入力層から隠れ層に入ったデータ x_t はLSTMブロック内での再帰構造により、過去の入力データの影響を受ける。本モデルでは過去3週間の週次変化を表す以下のベクトルを入力層のデータとして学習に用いる。

$$x_t, x_{t-1}, x_{t-2}$$

本モデルで設定した隠れ層におけるLSTMブロックの構造は以下の通りである。

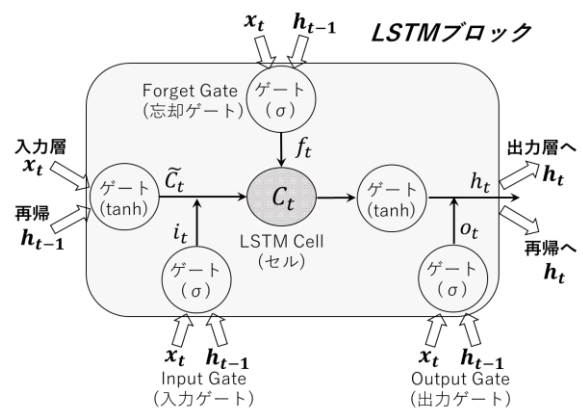


図6: LSTMブロックの説明

入力層からのデータ x_t と再帰データ h_{t-1} は、LSTM ブロックに入った後、ゲート（活性化関数）を通じて以下のように \tilde{C}_t として変換される。

$$\tilde{C}_t = \tanh(W_c \cdot [x_t, h_{t-1}] + b_c)$$

LSTM ブロック内の \tilde{C}_t は、更に入力ゲートと忘却ゲートからの出力値 i_t, f_t によって更新され C_t となる。ここでの活性化関数 σ はシグモイド関数とする。

$$i_t = \sigma(W_i \cdot [x_t, h_{t-1}] + b_i)$$

$$f_t = \sigma(W_f \cdot [x_t, h_{t-1}] + b_f)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

更に C_t は、 \tanh で設定されるゲートを通過した後、出力ゲートからの出力値 o_t によって出力がコントロールされ、最終的に隠れ層から h_t が出力される。

$$o_t = \sigma(W_o \cdot [x_t, h_{t-1}] + b_o)$$

$$h_t = o_t * \tanh(C_t)$$

そして、隠れ層の出力値 h_t は、下式の通り線形活性化関数を介して出力層 y_t に繋がる。

$$y_t = Vh_t + C$$

本研究では、このような LSTM ベースのモデルを用いて、長期金利と他年限金利の関係（金利の期間構造）を考慮したイールドカーブの変動モデルの作成を行った。そして、作成したモデルを用いて予測した 1 週間先のイールドカーブの変化に基づいて、長期金利の上昇、低下の方向性の予測精度の検証を行った。ここでは、前節での他手法との比較のために、学習に用いたデータ期間及び、検証に使用したテストデータの期間は、前節で用いたもの同一の期間とした。検証結果は図 7 の「LSTM (期間構造導入)」に示した通りである。本検証結果に基づくと、長期金利の予測精度に改善の傾向が見られた。

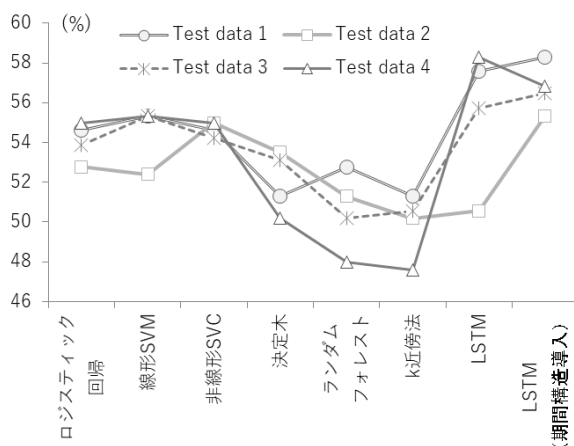


図 7: 長期金利の方向性予測の正答率

ただし、今回確認された LSTM モデルの優位性はあくまで時系列特性に依存するものであり、テストデータによっては、SVM 等と正答率が同程度のケースも見受けられる。本分析で対象とした長期金利の変動は、図 1 に示した通り、時期によってその大きさが変化しており、例えばサンプル期間中においては、1990 年代に金利変動の大きさが目立っている。一方、足元では日本銀行による「長短金利操作付き量的・質的金融緩和」[4]の下、長期金利（10 年国債の利回り）が概ねゼロ%程度で推移するような長期国債の買入れが行われており、長期金利の変動性は低下している。このように、マクロ経済環境や金融政策運営等を背景に、金利の時系列特性も変化していく点には注意が必要である。

まとめと解釈

本研究では、LSTM ベースの機械学習手法を用いてイールドカーブの変動モデルの構築を行った。特に、年限間の相対価値 (Relative Value) に基づいて国債の需要が変動する市場特性や、周辺年限の国債との金利差に着目した裁定取引の存在等、イールドカーブの変動が、イールドカーブの形状という内生的な要因によって生み出される点に着目し、金利の期間構造を考慮したイールドカーブの変動モデルの構築を行った。結果、金利の期間構造を考慮した予測モデルを用いた場合、長期金利の単一時系列を用いた予測モデルに比べて、予測精度に改善の傾向が見られた。このことは、長期国債の市場価格の形成に影響を与え得る国債の年限間の相対価値の情報が、長期金利予測において有用な情報となることを示唆する結果と言えよう。

留意事項

本稿は、著者の個人見解を表すものであり、野村證券株式会社の公式見解を表すものではありません。

参考文献

- [1] Sepp Hochreiter, Jürgen Schmidhuber: Long Short-Term Memory, Neural Computation, Vol.9, No.8, pp.1735–1780, (1997)
- [2] 松井藤五郎, 汐月智也: LSTM を用いた株価変動予測, 人工知能学会第 31 回全国大会論文集, (2017)
- [3] 財務省: 国債金利情報
https://www.mof.go.jp/jgbs/reference/interest_rate/
- [4] 日本銀行: 金融緩和強化のための新しい枠組み「長短金利操作付き量的・質的金融緩和」, (2016)