

# 日米イールドカーブの連動性を用いた 機械学習に基づく日本国債の長期金利予測

JGB long-term interest rate forecast considering  
the connection between the Japanese and US yield curve

水門善之<sup>1,2\*</sup> 坂地泰紀<sup>1</sup>

和泉潔<sup>1</sup> 島田尚<sup>1</sup> 松島裕康<sup>1</sup>

Yoshiyuki Suimon<sup>1,2</sup> Hiroki Sakaji<sup>1</sup>

Kiyoshi Izumi<sup>1</sup> Takashi Shimada<sup>1</sup> Hiroyasu Matsushima<sup>1</sup>

<sup>1</sup> 東京大学大学院工学系研究科システム創成学専攻

<sup>1</sup> Department of Systems Innovations, School of Engineering  
The University of Tokyo

<sup>2</sup> 野村証券株式会社金融経済研究所経済調査部

<sup>2</sup> Economic Research Department, Financial and Economic Research Center  
Nomura Securities Co., Ltd.,

**Abstract:** 近年、リーマンショックや欧州債務危機に代表される海外発の金融システム不安が、デリバティブ契約等のグローバルな金融取引を通じて、日本の金利市場に大きな影響を与える場面が散見されてきた。この点を踏まえ、本研究では海外市場での金利変動が日本の金利市場に与える影響を検証すると共に、機械学習手法を用いて、海外市場からの影響を考慮した日本市場の金利変動モデルの構築を行った。具体的には、日本国債のイールドカーブの変動を対象として、各種機械学習手法を用いて先行きの予測モデルを構築する際に、米国債のイールドカーブの変動データも学習データとして用いることで、日本の長期金利（長期国債の利回り）の予測精度が向上する傾向を確認した。更に、米国市場のデータを学習に用いた場合に、日本市場の予測精度が向上する度合いが、近年高まっていることも併せて確認した。このことは、海外金利の情報が現在の日本市場の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。

## 1. 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。他にも、リーマンショックや欧州債務危機に代表される海外発の金融システム不安、また欧米中央銀行の金融政策変更等を受けた海外市場での金利変動が、日本の金利市場に影響を与える場面も散見される。これらの背景には、デリバティブ契約等のグローバルな金融取引や様々な金利裁定取引を通じて、海外市場における金利変動が、直接的

に日本市場の金利に伝達されるメカニズムが存在していること等が挙げられよう。

本研究では、このように海外市場における金利変動が日本の金利市場に与える影響に着目することで、日本の金利市場の先行きを予測する上での、米国市場データの有用性の検証を行う。始めに、日米の金利データの連動性の検証、及び実際の金融市場参加者を対象としたアンケート結果を用いて、日本の市場参加者が海外データをどの程度考慮して取引を行っているかの検証を行う。その結果を踏まえ、各種機械学習手法（SVM、非線形SVM、決定木、RF、ロジスティック回帰、k近傍法、MLP、RNN、LSTM）を用いた日本市場の金利の変動予測モデルの構築を行う。その際、日本市場の過去の金利の変動データ

---

\* Email: d2018ysuimon@socsim.org

に加えて、米金利市場の金利の変動データも学習に用いたモデルを提案し、本提案モデルを用いた場合に、日本の長期金利（長期国債の利回り）の予測精度がどの程度向上するかについての検証を行う。更に、前述した昨今の金融システムのグローバル化に伴って、米国市場が日本市場に与える影響が近年上昇していることが想定されることから、この点についても、学習モデルを用いた金利予測のシミュレーションにより、日本市場の予測における米国市場データの有用性が、近年どの程度高まっているかについての検証を行う。

## 2. イールドカーブと長期金利

### 2.1 長期金利と日米金利

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。

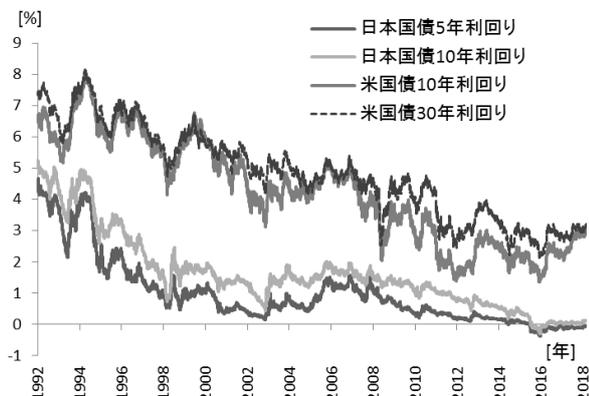


図 1: 日米国債利回りの推移

実際の日本の長期金利（10年国債利回り）の推移を図 1 に示した。また、日本国債の他年限の金利、

並びに、米国債市場の金利データも併せて掲載した。これによると、日米において金利水準の変化はある程度連動しており、また近年は金利水準の低下が生じていることが見て取れる。

### 2.2 国債イールドカーブの期間構造モデル

日米の長期金利の推移は図表 1 に示した通りだが、この他にも様々な年限の金利が存在している。例えば日本では 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。このような異なる年限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）。

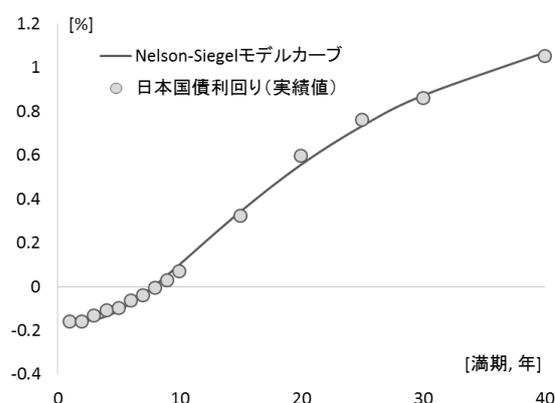


図 2: Nelson-Siegel モデルに基づくイールドカーブ

イールドカーブの形状は、金利の期間構造モデルを用いて表すことができる。例えば、Nelson-Siegel モデル[1]を用いると、以下のような関数形を用いてイールドカーブの期間構造が表現できる。ここでは  $y$  は金利、 $\tau$  は年限、 $\lambda$  は定数とする、

$$y(\tau) = F_1 + F_2 \left( \frac{1 - e^{-\lambda\tau}}{\lambda\tau} \right) + F_3 \left( \frac{1 - e^{-\lambda\tau}}{\lambda\tau} - e^{-\lambda\tau} \right) \quad (1)$$

この関数は、水準、傾き、曲率を表す 3 つのファクター  $F$  の項から成り立っており、それぞれのファクターの年限別の係数を図示すると図 3 のようになる。このような金利の期間構造モデルによって表現される国債金利のイールドカーブだが、基本的にはこれらの金利水準は、マクロ経済環境や金融政策の影響を受けて変動する。ただし、年限によっては国債取引を行う市場参加者の特性や取引目的が異なることから、結果、金利の変動特性も年限によって異なってくる。

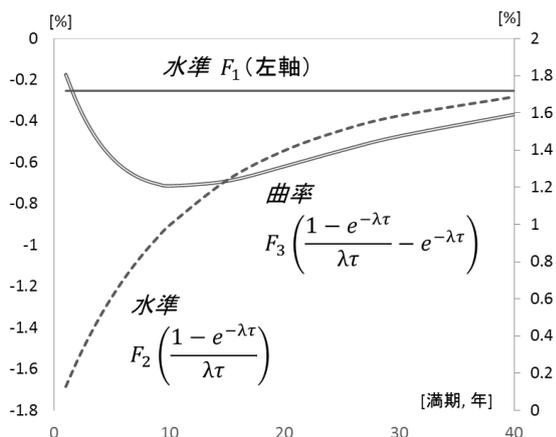


図 3: Nelson-Siegel モデルに基づくイールドカーブ

例えば、日本のマーケットにおいては、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ため変動性は乏しい。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柔軟に変動していく。また、年限間の金利差が開きすぎた場合には、高い金利の国債の需要が高まり、結果、金利差に縮小圧力がかかるというメカニズムも存在する。このように、国債イールドカーブは、年限間の相対価値 (Relative Value) や周辺年限の国債との金利差に着目した裁定取引の影響等を受けながら、イールドカーブの形状自身に基づく内生的な要因によって、自身の変動が生み出されていく側面もある。

### 2.3 イールドカーブモデルの構築

本研究では、イールドカーブの期間構造の変動をモデル化するにあたり、水準・傾き・曲率の情報を、5・10・20年の金利変化のデータを用いることで設定したい。図4に示す通り、3つの主要な年限の金利変化の情報を用いることで、各年限の金利水準の変化に加えて、イールドカーブの傾き・曲率の変化の情報も捉えることができる。例えば、5-20年のスプレッド (金利差) はイールドカーブ全体の傾きとして、5-10年スプレッドと10-20年スプレッドの差はイールドカーブ全体の曲率としての意味を持つ。このように3つの年限の金利変化の情報を用いて、金利の期間構造の変化をモデル化することで、前述した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長期金利の変動特性を捉えたモデルの構築を行う。

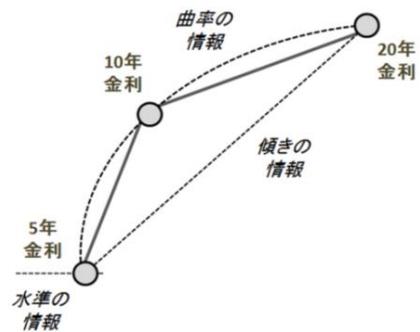


図 4: 金利の期間構造を表す3つのファクター

## 3. 日米イールドカーブの連動性

### 3.1 日本の市場参加者が意識する海外金利

前述の通り、長期金利の変動は他年限の金利との相対関係の影響も受けるが、その他にも海外市場の影響も受けることが想定される。図1で示した通り、日米の金利は、ある程度の連動性が見られる。実際、日本の国債市場の参加者は、海外市場の動きをどの程度気にしているのだろうか。この点を考える上で参考になるのが、QUICK社が毎月、日本の債券市場の参加者を対象に実施しているアンケート調査“QUICK月次調査<債券>”だ。

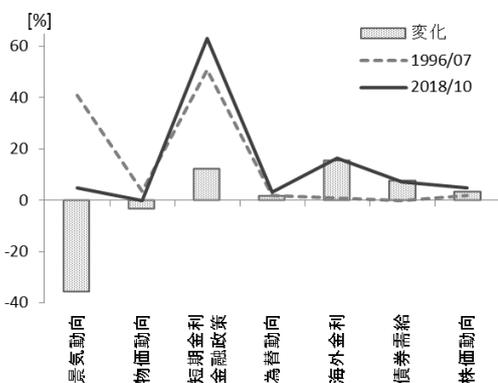


図 5: 債券市場参加者が注目する価格変動要因

本アンケートの中には「最も注目している債券価格変動要因は？」という質問項目があり、図5に示す通り、調査が始まった1996年時点では、債券市場の参加者の中では「金融政策や短期金利」の次に「景気動向」との回答割合が高かった。ただし、2018年時点では「景気動向」に替わって「海外金利」と回答する割合が増えてきている。

図6は、同アンケート調査における「景気動向」と「海外金利」との回答の割合の推移を示したものだ。これによると、2006年頃から「海外金利」の回

答割合が高まってきている傾向が見て取れる。それと同時に「景気動向」の回答割合は低下傾向にあることが分かる。

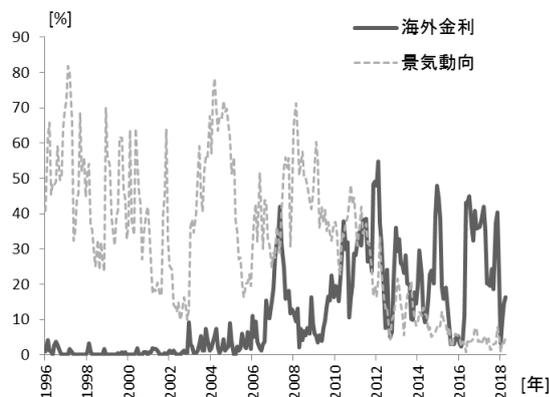


図 6: 債券市場参加者が注目する価格変動要因の推移

実際、2008年のリーマンショックや2010年に発生した欧州債務危機に代表される海外発の金融システム不安、更には欧米中央銀行の金融政策変更やそれに向けた投資家の動きといった、海外金融市場における様々な変動要因が、日本の金利市場の価格形成に大きな影響を与える場面は、近年散見されている。背景には、グローバルな金融機関の間で締結されるデリバティブ契約や、様々な金利裁定取引を通じて、海外金利の変動が直接的に日本の金利に伝達するメカニズムの存在等が想定できよう。そのため、このように、グローバルな金融システムが発達した現代においては、日本の金利とはいえ、日本の景気動向といったファンダメンタルズ要因のみならず、海外市場における金利変動の影響が市場参加者の間で強く意識され、結果として、それが日本国内の金利市場における価格形成に影響を与えている可能性はあるだろう。

### 3.2 日米金利の連動性確認の為の予備実験

本節では、このような市場参加者のアンケート結果を踏まえて、実際に日米のイールドカーブが、互いにどのような影響を与えているかについて、簡単な検証を行った。図7は、日米の日次の金利データを対象として、各年限の米国（日本）の金利が上昇（低下）した翌日に、日本（米国）の市場で同年限の金利が上昇（低下）した割合を示したものだ。これによると、米国の金利が上昇（低下）した翌日には、日本の金利も同方向の動きをする傾向が見られる。一方で、その逆である日本市場から米国市場への金利変動の連動性は限られている。また、前述のアンケート結果を踏まえ、図7では、1992年から2005年の期間及び、2006年から2018年の期間に分けて

検証を行ったが、2006年以降の期間で見た場合、このような非対称性の傾向はより強まっていることが確認できる。特に、10年金利において、日本金利が米国金利の動きに連動する傾向が強い点を踏まえると、日本の長期金利の日次変動予測において、米国市場のデータの有用性が窺えよう。

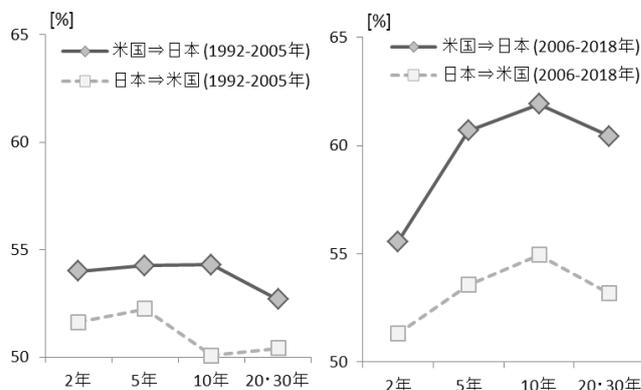


図 7: 日米国債利回りの日次連動性の検証

## 4. 機械学習モデルの構築と金利予測

### 4.1 特徴量エンジニアリング

本章では、これまでの論点を踏まえ、機械学習モデルを用いた日本の長期金利の予測を行う。日本市場の金利データを対象に、機械学習手法に基づく金利の期間構造モデルを用いて、長期金利の予測を行った先行研究としては、[2]が挙げられる。本研究では、先行研究と同じく日本市場の金利データのみを学習に用いたモデルで日本の長期金利を予測した場合と、それに加えて、米国市場の金利データも学習に用いたモデルで日本の長期金利を予測した場合とで、予測精度がどの程度改善するかについて検証を行う。

まず、2.3節で言及した通り、日本国債（JGB）の5,10,20年の金利変化のデータを用いて金利の期間構造のモデル化を行う。具体的には、各年限（5,10,20年）の過去3日間の日次の金利変化をインプットデータとし、更に、各年限の翌日にかけての金利変化をラベルデータとして、機械学習に基づく金利の期間構造の変動モデルを構築する。学習に用いるインプットデータとラベルデータの関係は図8に示した通りである。本モデルにより、5,10,20年の3つの年限の3日分の金利変化のデータを基に、各年限の翌日にかけての金利変化が予測可能となる。

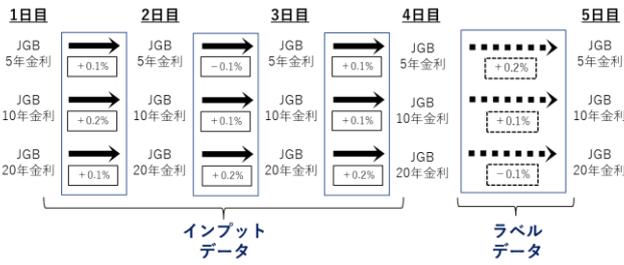


図 8: インプットデータとラベルデータの設定 (日本市場データ対象時)

次に、日本市場の金利データに加えて、米国市場の金利データも学習に用いたモデルを構築する. 具体的には、過去 3 日間の日本国債 (JGB) の 5,10,20 年の金利変化に加えて、過去 3 日間の米国債 (UST) の 5,10,30 年の金利変化もインプットデータとし、その翌日にかけての日本国債の 5,10,20 年の金利変化をラベルデータとして、モデルの学習を行う. 学習に用いるこれらインプットデータとラベルデータの関係は図 9 に示した通りである.

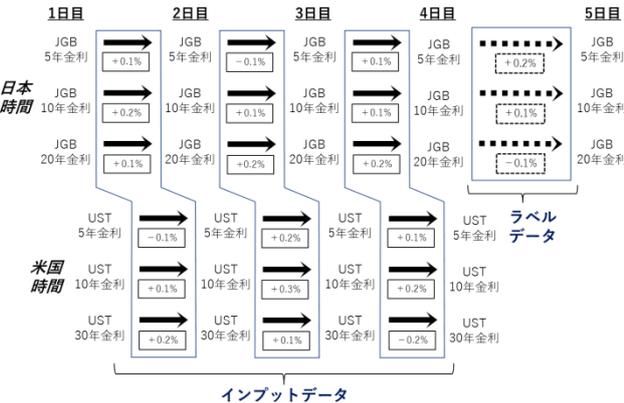


図 9: インプットデータとラベルデータの設定 (日米市場データ対象時)

ポイントとなるのが、日本時間と米国時間の違いだろう. 米国市場の終値のデータが得られるのは、同日の日本市場が閉じた半日程度後である. また、日本時間の 5 日目の市場が開く前に 4 日目の米国時間の取引が終了するため、両市場の取引時間は重複しない. この点を踏まえ、日本の 5,10,20 年金利に加えて、米国の 5,10,30 年金利のデータをインプットデータとして用いることで、翌日にかけての日本の金利変化の予測精度向上を目指す.

#### 4.2 金利の変動モデルの構築

本研究では、1992 年 8 月から 2018 年 9 月までの日本及び米国の国債利回りの日次変化のデータを対象として、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), DT (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, 更には MLP (多層パーセプトロン), RNN (リカレントニューラルネットワーク), LSTM (ロングショートタームメモリ) に基づく、モデルの実装を行う [3][4]. なお、日本国債の利回りは財務省より、米国債の利回りは米連邦準備銀行より公表されている. モデルの学習の際には、SVM, 決定木, RF, ロジスティック回帰, k 近傍法においては、過去 3 日間の金利変化の情報 (3 日分の日本国債の 5 年, 10 年, 20 年の金利変化, また比較対象としては、これらに加えて米国債の 5 年, 10 年, 30 年の金利変化) をインプットデータとし、翌日の日本国債の 10 年金利の変化が上昇か低下かの二値を教師ラベルとして、学習を行う.

また、MLP の場合は、過去 3 日間の金利変化の情報 (3 日分の日本国債の 5 年, 10 年, 20 年の金利変化, また比較対象としては、これらに加えて米国債の 5 年, 10 年, 30 年の金利変化) をインプットデータとし、翌日の日本国債の 5 年, 10 年, 30 年の金利変化の情報を教師ラベルとして学習を行う. ネットワークの模式図は図 10 に掲載した通りである. 米国のデータを用いる場合、インプットデータのベクトルが 6 次元 (=3 つの年限の金利変化 × 2 カ国) となる一方、アウトプットのベクトルは日本の 5 年, 10 年, 20 年の金利変化に対応した 3 次元となる.

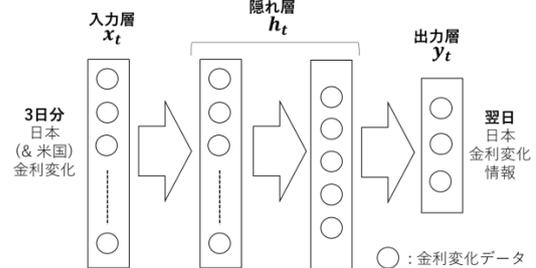


図 10: MLP におけるニューラルネットワークの構造

更に、RNN, LSTM に基づく学習モデルの場合は  $t-1$  日から  $t$  日にかけての日本国債の 5 年, 10 年, 20 年の金利変化という 3 次元のベクトルを入力データ  $x_t$  として設定する (比較対象として、米国の情報も用いる場合は、これらに加えて米国金利の 5 年, 10 年, 30 年の金利変化も入力データとして使用する).

$$x_t = \begin{pmatrix} r_t^{JP20} - r_{t-1}^{JP20} \\ r_t^{JP10} - r_{t-1}^{JP10} \\ r_t^{JP5} - r_{t-1}^{JP5} \\ r_t^{US30} - r_{t-1}^{US30} \\ r_t^{US10} - r_{t-1}^{US10} \\ r_t^{US5} - r_{t-1}^{US5} \end{pmatrix}, y_t = \begin{pmatrix} r_{t+1}^{JP20} - r_t^{JP20} \\ r_{t+1}^{JP10} - r_t^{JP10} \\ r_{t+1}^{JP5} - r_t^{JP5} \end{pmatrix}$$

そして、これらの過去 3 日間の変化  $x_t, x_{t-1}, x_{t-2}$  をリカ

レントなネットワークにおけるインプットデータ、更に  $t$  日から  $t+1$  日にかけての 5 年、10 年、20 年の金利変化のベクトル  $y_t$  を教師ラベルとして、モデルの学習を行う。

表 1: 各機械学習モデルの構造リスト

表記	モデル	モデル構造
Same	前日と同じ方向	JP: 前日の日本市場の動きと同方向 JP&US: 昨日の米国市場の動きと同方向
LinRe	線形回帰(重回帰)	
LogiRe	ロジスティック回帰	正則化パラメータ C=1
LinSVM	サポートベクターマシン(線形)	ペナルティパラメータ C=1
SVM	サポートベクターマシン(非線形)	ガウシアンカーネル使用 ペナルティパラメータ C=1
DT	決定木	
RF	ランダムフォレスト	
kNei	k近傍法	k=5
MLP1	多層パーセプトロン	活性化関数: ハイバボリックタンジェント 各レイヤーのノード数 JP: 9-5-3, JP&US: 18-10-3
MLP2	多層パーセプトロン	活性化関数: ハイバボリックタンジェント 各レイヤーのノード数 JP: 9-9-5-3, JP&US: 18-18-10-3
RNN1	リカレントニューラルネットワーク	活性化関数: ハイバボリックタンジェント 隠れ層のノード数: 100
RNN2	リカレントニューラルネットワーク	活性化関数: ハイバボリックタンジェント 隠れ層のノード数: 50
LSTM1	ロングショートタームメモリ	活性化関数: ハイバボリックタンジェント リカレント活性化関数: シグモイド LSTMブロックの数: 100
LSTM2	ロングショートタームメモリ	活性化関数: ハイバボリックタンジェント リカレント活性化関数: シグモイド LSTMブロックの数: 50

## 5. 予測モデルの評価と検証

### 5.1 学習モデルの長期金利予測精度の検証

本章では、前述した各種学習モデルに基づく日本の長期金利（10 年国債利回り）予測の検証結果を示す。ここでは、QUICK 社のアンケート結果、及び III-B 章で行った予備実験の結果を踏まえ、サンプル期間を 1992 年から 2005 年までの期間と、2006 年から 2018 年までの期間に分けて検証を行った。検証方法としては、各サンプル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 割をテストデータとして学習済みモデルの予測精度を検証した。

具体的には、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の検証においては、テストデータに対して、学習済みモデルを用いて直接予測を行った翌日の 10 年金利の方向性を、実際の方向性と比較することで予測精度の検証を行っ

た。MLP、RNN、LSTM に基づく予測モデルの検証では、テストデータに対して、学習済みモデルを用いて予測した翌日の 10 年金利の変動幅に基づく方向性と、実際の方向性との比較を行った。また、本検証においては、米国市場のデータを学習に使用した場合と、使用しなかった場合との比較の為に、学習に用いたデータの期間及び、検証に使用したテストデータの期間は、両分析において共通の期間としている。各機械学習モデルの構造については表 1 を参照されたい。

### 5.2 考察

各種モデルに基づく、日本の長期金利の翌日の上昇・低下の方向性予測の正答率を図 12 に掲載した。ここでは、モデルの学習の際に日本市場の金利データのみを用いた場合（米国データ未使用）と、米国市場の金利情報も学習に用いた場合（米国データ使用）とに分けて、長期金利の予測精度を示した。更に図 11 では、二つの図表を用いて、2006 年以前と以降の期間を対象に、各 2 種類のテストデータを用いた正答率を示したが、これによると、米国市場の金利データを学習に用いた場合、2006 年以降の期間において、日本の長期金利の予測精度に大幅な改善が確認できる。

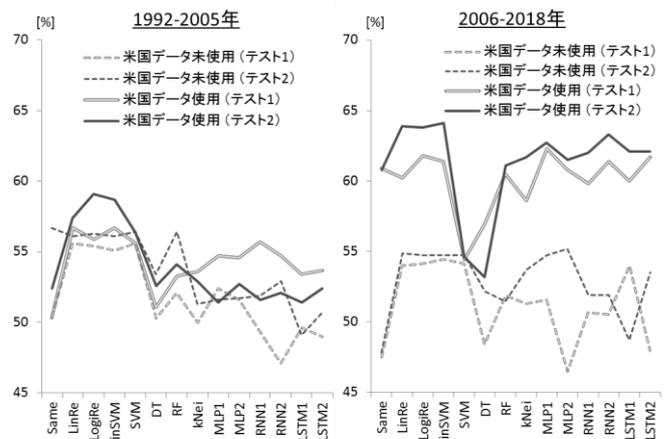


図 11: 各モデルに基づく日本の長期金利予測の正答率

2006 年以降の期間では、いずれの学習アルゴリズムを用いた場合でも、米国市場の金利データを学習に用いることによる予測精度の改善が顕著であり、特に、ロジスティック回帰や SVM、また各種ニューラルネットワークに基づくモデルを用いた場合、同程度に良好な予測パフォーマンスが確認できた。このことは、前述のアンケート結果や予備実験が示唆したように、近年、米国金利の情報が、翌日の日本の長期金利の動向を予測する上で、有用な情報となることを示す結果と言えよう。

## 6. 関連研究

本研究では、日米の国債市場における金利の期間構造の変動を機械学習手法を用いてモデル化し、それに基づいて日本の長期金利の変動予測を行った。本研究に関連する先行研究としては、本研究でも着目した Nelson-Siegel モデル[1] を用いて米国債市場のイールドカーブをモデル化し、更に Nelson-Siegel モデルの3つのファクターの変化を時系列分析手法の一種である AR(1)モデルを用いて予測した[5]が挙げられる。

イールドカーブに対するファクター分析としては、主成分分析を用いて3つの主成分ファクターを抽出し、各ファクターの時系列をモデル化することで、イールドカーブ変化の予測を行った[6]も挙げられる。また、主成分分析を用いたアプローチとして、[7]や[8]は、様々なマクロ指標を対象として主成分分析を行い、それによって作成したマクロベースの主成分ファクターを金利の予測に活用するといった研究も行っている。

更に、深層学習等の機械学習手法をイールドカーブ変動の予測に用いた研究としては、[2]が挙げられる。[2]は、Nelson-Siegel モデルの3つのファクターの代わりに、イールドカーブの3点（5年、10年、20年）の金利の相対関係に着目することで、金利の期間構造を表現し、かつそれらの変動を LSTM を含む機械学習手法を用いてモデル化することで、長期金利の予測を行った点が特徴的である。

## 7. 結論

本研究では、米国市場の金利変動が、日本市場に与える影響に着目することで、各種機械学習手法を用いた日本市場の金利変動予測における、米国市場の情報の有用性の検証を行った。具体的には、先行研究[2]の手法にならう形で日本市場の金利データのみを学習に用いて日本の長期金利を予測した場合と、それに加えて、米国市場の金利データも学習に用いて日本の長期金利を予測した場合とで、どの程度予測精度が改善するかについて検証を行った。その結果、日本市場の金利データに加えて、米国市場の金利データも学習に用いることで、特に近年においては、日本の長期金利予測の精度が大きく向上する傾向が確認できた。このことは、日本国債の市場参加者を対象に行ったアンケート調査において、2006年頃以降、海外金利を注視する傾向が強まりをみせている点と整合的であろう。近年の金融市場においては、海外発の金融危機や、海外中銀の金融政策変更といった、海外における様々な金利の変動要

因が、グローバルな金融機関同士のデリバティブ契約や、様々な金利裁定取引を介して、直接的に日本市場の金利に影響を与え得るパスが存在している。本研究の結果は、このような、グローバルな金融システムが発達した現代において、海外金利の動向が、国内金利の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。

## 参考文献

- [1] Charles Nelson and Andrew F Siegel, “Parsimonious Modeling of Yield Curves,” *The Journal of Business*, Vol.60, No.4, pp.473-489, 1987
- [2] 水門善之, “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,” 人工知能学会金融情報学研究会, No.21, pp.46-49, 2018
- [3] Sepp Hochreiter and Jürgen Schmidhuber, “Long Short-Term Memory, *Neural Computation*,” Vol.9, No.8, pp.1735-1780, 1997
- [4] Felix A. Gers, Jürgen Schmidhuber and Fred A. Cummins, “Learning to Forget: Continual Prediction with LSTM,” *Neural Computation*, Vol.12, No.10, pp.2451-2471, 2000
- [5] Francis X. Diebold and Canlin Li, “Forecasting the term structure of government bond yields,” *Journal of Econometrics*, Vol.130, pp.337-364, 2006
- [6] Haim Reisman and Gady Zohar, “Short-Term Predictability of the Term Structure,” *The Journal of Fixed Income*, Vol.14, No.3, pp7-14, 2004
- [7] Emanuel Moench, “Forecasting the yield curve in a data-rich environment: A no-arbitrage factor-augmented VAR approach,” *Journal of Econometrics*, Vol.146, No.1, pp26-43, 2008
- [8] Sydney C. Ludvigson and Serena Ng Author, “Macro Factors in Bond Risk Premia,” *The Review of Financial Studies*, Vol.22, No.12, pp.5027-5067, 2009

## 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。