

LSTM ネットワークによる財務データの回帰分析

Regression Analysis of Corporate Financial Data using LSTM Networks

城内 光平^{1*} 江口 浩二¹ 金京 拓司² 羽森 茂之²

¹ 神戸大学大学院システム情報学研究科

¹ Graduate School of Systems Informatics, Kobe University

² 神戸大学大学院経済学研究科

² Graduate School of Economics, Kobe University

Abstract: In the economic and financial fields, there is a growing interest in obtaining new knowledge from large quantities of data, such as corporate financial data and international exchange transactions. On the other hand, as a technical trend of recent data analysis, deep learning-based models have been successfully applied to various data, such as images, text, and audio. Especially, Recurrent Neural Network (RNN) and its extension of Long Short-Term Memory Network (LSTM) have been developed as deep learning for sequential data or time series. However, regardless of its importance, LSTM has not applied to corporate financial time series, such as in the Financial Statements Statistics of Corporations, to the best of my knowledge. In this research, considering the above-mentioned trends, we conduct regression analysis using LSTM for corporate financial time series. For experiments, we obtain the capital investment rate and other financial indicators, such as the cash flow ratio, for each target company from the Financial Statements Statistics of Corporations, and then use them as the objective and explanatory variables, respectively. By changing the number and types of explanatory variables used in the experiments, we evaluate the contribution of each explanatory variable to regression power to the objective variable at several time steps ahead. Furthermore, as baseline methods for the regression tasks, we evaluate the regression power of classical methods: Autoregressive Integrated Moving Averaging (ARIMA), and discuss the comparative evaluation with the LSTM approach.

1 はじめに

近年、情報技術の発達に伴い、日々多くの情報が収集、蓄積されている。その分野は多岐にわたり、枚挙に暇がないが、その一つに、経済・金融分野における企業財務データや国際為替取引情報が挙げられる。それらの分野の専門家達の間でも、これらの大量に蓄積されつつあるデータを活かして新たな知見を得ることに関心が高まりつつある。とりわけ、法人企業統計調査¹等の企業財務データは、企業の経営方針や業界の動向、さらには社会の景況感など、実世界の情報を多く含む複雑な時系列データとなっている。

最近のデータ分析の技術的な側面に目を向けると、画像やテキスト、音声など様々なデータに対して深層学

習を用いたモデルが適用され、その有効性が示されている。その中でも、系列データを扱う深層学習のモデルとして、再帰型ニューラルネットワーク (Recurrent Neural Network : RNN)[1]、およびその拡張である長短期メモリネットワーク (Long Short-Term Memory Network : LSTM)[2] が挙げられる。RNN は長期間に渡る時間依存性に対しては勾配消失あるいは勾配爆発の問題のために、上手くこれらの関係性を捉えることができないことが少なくない。これらの欠点を改善し、長期間に渡る時間依存性を考慮することのできるモデルとして LSTM が提案されている。また応用例として、Google 社の音響モデリングシステム [3] をはじめ、複雑なデータセットに対して複数層の LSTM からなるアーキテクチャを適用しこれまでのモデルを越える成果を残している。しかしながら、先に述べた企業財務に関する時系列データに対する LSTM の適用事例は、その重要性に関わらず筆者の知る限りない。

*連絡先：神戸大学大学院システム情報学研究科
〒657-0029 兵庫県神戸市灘区六甲台町 1-1
E-mail: shirouchi@cs25.scitec.kobe-u.ac.jp

¹<http://www.mof.go.jp/pri/reference/ssc/index.htm>

本論文においては、以上に述べた動向を踏まえた上で、法人企業統計調査における企業の財務報告に対して、LSTMを用いた回帰分析を行う。本実験においては、法人企業統計調査より、設備投資率と、キャッシュフロー比率を初めとした種々の財務指標を算出し、それぞれ被説明変数および説明変数として用いている。特に、設備投資率とキャッシュフロー比率との間の関係性に専門家の注目が集まっている [6], [7]。また、実験に用いる説明変数の数や種類を変化させることで被説明変数に対する回帰精度への影響を評価し、回帰分析の対象とする財務指標と他の財務指標との依存性を推定する。

比較手法として、古典的な時系列解析手法である自己回帰和分移動平均 (Autoregressive Integrated Moving Average; ARIMA) [8] による分析を行い、比較評価について議論する。

2 関連研究

本研究においては、企業の活動の状態を表す財務指標に対して、深層学習の手法を用いて分析、および予測に関する検討を行う。そこで、本章では時系列データの解析によく用いられる深層学習の手法である、再帰型ニューラルネットワーク (Recurrent Neural Network: RNN)、およびその拡張である長短期記憶メモリネットワーク (Long Short-Term Memory network: LSTM) を紹介する。

2.1 再帰型ニューラルネットワーク

系列データは個々の要素が順序を持ち、その並びに意味が隠されているようなデータのことである。系列の並びが時刻の並びとなっている系列データを特に時系列データと呼ぶ。系列データの例としては音声の波形、動画、文章 (単語列) などがある。それにより、系列データの分類問題においてはある時刻、もしくは位置におけるデータの前後におけるデータとの関係性を上手く考慮することができれば、結果が向上することが知られている。そして順伝播型ニューラルネットワークを系列データを扱うために拡張したモデルとして再帰型ニューラルネットワーク (Recurrent Neural Network: RNN) [1] がある。RNN は入力の系列 $\mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3, \dots$ から正解の系列 $\mathbf{y}^1, \mathbf{y}^2, \mathbf{y}^3, \dots$ を推定する問題として定式化することができる。このとき時刻 t における出力 \mathbf{y}^t はそれ以前の入力 $\mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3, \dots, \mathbf{x}^t$ の影響を受けていると考えることができる。

RNN は内部に有向な閉路を持つニューラルネットの総称である。RNN はこの構造により情報を一時的に記憶し、また振る舞いを動的に変化させることができる。




図 1: Graphical model of RNN.

これにより、系列データ中に存在する時間的な依存関係である「文脈」を捉えることができ、系列データに対して有効に処理することができる。RNN のグラフィカルモデルを図 1 に示す。

図 1 にあるように RNN は FFNN と同様の構造を持ち、ただし中間層のユニットの出力が自分自身に戻される「帰還路」を持っている。RNN の動作は各時刻 t につき 1 つの入力 \mathbf{x}^t を受け取り、また同時に 1 つの出力 \mathbf{y}^t を返すというものである。RNN は理論上、過去のすべての入力から 1 つの出力への写像を表現する。中間層に十分な数のユニットがあれば、任意の系列から系列への写像を、任意の精度で近似することができることが証明されている。

本研究では、出力層の活性化関数は恒等関数、誤差関数には二乗誤差関数を用いている。

2.1.1 順伝播計算

RNN における計算の過程を示す。ネットワークへの入力を $\mathbf{x}^t = (x_i^t)$ 、中間層への入出力をそれぞれ $\mathbf{u}^t = (u_j^t)$ 、 $\mathbf{z}^t = (z_j^t)$ 、出力層ユニットへの入出力をそれぞれ $\mathbf{v}^t = (v_k^t)$ 、 $\mathbf{y}^t = (y_k^t)$ とする。また目標出力を $\mathbf{d}^t = (d_k^t)$ とする。RNN の帰還路は、中間層の出力を自らの入力に戻し、この間の結合は全ユニット間で存在する。したがって、時刻 $t-1$ 中間層の任意のユニット j' から時刻 t 中間層の任意のユニット j へ重み $W_{jj'}$ の結合が存在する。よって、時刻 t における中間層の任意のユニット j への入力は以下ようになる。

$$u_j^t = \sum_i w_{ji}^{(in)} x_i^t + \sum_{j'} w_{jj'} z_{j'}^{t-1} \quad (1)$$

これを用いて、中間層の出力は活性化関数 f を用いて以下のように求めることができる。

$$z_j^t = f(u_j^t) \quad (2)$$

$$\mathbf{z}^t = \mathbf{f}(\mathbf{W}^{(in)} \mathbf{x}^t + \mathbf{W} \mathbf{z}^{t-1}) \quad (3)$$




図 2: Memory unit of LSTM.

よって、出力層の入出力 $\mathbf{v}^t = (v_k^t)$, $\mathbf{y}^t = (y_k^t)$ は以下のように求められる。

$$v_k^t = \sum_j w_{kj}^{(out)} z_j^t \quad (4)$$

$$\mathbf{y} = \mathbf{f}^{(out)}(\mathbf{v}^t) = \mathbf{f}^{(out)}(\mathbf{W}^{(out)} \mathbf{z}^t) \quad (5)$$

2.2 長短期記憶メモリネットワーク

RNN は系列データの文脈を捉えて推定を行うことができる。このとき、捉えることのできる文脈の長さ、すなわち現時刻からどれだけ遠い過去の入力を出力に反映させることができるかは重要である。しかし、RNN で実際に出力に反映することができるのは高々過去の 10 時刻分程度であると言われている。この限界は勾配消失問題により生じている。層の数の多い深いネットワークにおいて、誤差逆伝播法によって勾配を計算するときに層をさかのぼるにつれて勾配の値が爆発的に大きくなるか、あるいは 0 に消滅してしまう。長期にわたる記憶を実現するために提案されたモデルが長短期記憶ネットワーク (LSTM) である。LSTM では上で述べたような RNN に対し、その中間層の各ユニットをメモリユニットと呼ぶ要素で置き換えた構造を持っている。その他の構造は通常の RNN と同様である。メモリユニットの構造を図 2 に示す。

中央にメモリセル (図中記号 C) があり、その周囲に入力ゲート、出力ゲート、忘却ゲートが配置されている。メモリセル C は状態 s_j^t を保持し、これを 1 時刻隔ててメモリセル自身に帰還させることで記憶を実現している。この帰還路には途中に忘却ゲートが挿入されており、ユニット F の出力がゲートの値 $g_j^{F,t} \in [0, 1]$ となる。 s_j^t に $g_j^{F,t}$ をかけたものが伝えられ、 $g_j^{F,t}$ の値が 1 に近ければ現状態がそのまま記憶され、0 に近づればリセット (忘却) される。

メモリユニットへの外部からの入力は、外部からの入力と入力ゲートの値の積が入力される。ユニット I の出力がゲートの値 $g_j^{I,t} \in [0, 1]$ となる。

メモリユニットからの外部への出力は、メモリセルと出力ゲートからの値の積が出力される。ユニット O の出力がゲートの値 $g_j^{O,t} \in [0, 1]$ となる。ゲートの値が 1 に近ければメモリセルの出力は外部に伝達され、0 に近ければブロックされる。

これらの構造により短時間の記憶しか実現できないという RNN の限界を緩和することを目的としており、タイミングよくこれらのゲートの値を調整することにより、長い文脈を捉えたより高度な推定を実現する。

2.2.1 順伝播計算

時刻 t における入力ゲート、出力ゲート、忘却ゲートそれぞれの出力を \mathbf{i}_t , \mathbf{o}_t , \mathbf{f}_t 、メモリセルの状態を \mathbf{C}_t 、メモリユニットの出力を \mathbf{h}_t とすると、それぞれ以下のように求めることができる。

$$\begin{aligned} \mathbf{i}_t &= \sigma(\mathbf{W}_i \mathbf{x}_t + \mathbf{U}_i \mathbf{h}_{t-1} + \mathbf{b}_i) \\ \mathbf{C}_t &= \mathbf{i}_t \odot \tanh(\mathbf{W}_c \mathbf{x}_t + \mathbf{U}_c \mathbf{h}_{t-1} + \mathbf{b}_c) + \mathbf{f}_t \odot \mathbf{C}_{t-1} \\ \mathbf{f}_t &= \sigma(\mathbf{W}_f \mathbf{x}_t + \mathbf{U}_f \mathbf{h}_{t-1} + \mathbf{b}_f) \\ \mathbf{o}_t &= \sigma(\mathbf{W}_o \mathbf{x}_t + \mathbf{U}_o \mathbf{h}_{t-1} + \mathbf{V}_o \mathbf{C}_t + \mathbf{b}_o) \\ \mathbf{h}_t &= \mathbf{o}_t \odot \tanh(\mathbf{C}_t) \end{aligned} \quad (6)$$

ここで、 \mathbf{W}_i , \mathbf{W}_f , \mathbf{W}_c , \mathbf{W}_o , \mathbf{U}_i , \mathbf{U}_f , \mathbf{U}_c , \mathbf{U}_o , \mathbf{V}_o はそれぞれ重み行列であり、 \mathbf{b}_i , \mathbf{b}_f , \mathbf{b}_c , \mathbf{b}_o はバイアスである。 $\sigma(\cdot)$ はシグモイド関数、 $\tanh(\cdot)$ はハイパボリックタンジェント関数である。

時刻 t における入力 \mathbf{x}_t はメモリユニットに入力されると、入力ゲートの出力 \mathbf{i}_t とのアダマール積がメモリセルに入力される。 \mathbf{i}_t は時刻 t における入力 \mathbf{x}^t 、一時刻前の中間層の出力 h_{t-1} 、バイアスによって求められる。また、時刻 t におけるメモリセルの状態 \mathbf{C}_t は時刻 t における入力と時刻 $t-1$ のメモリセルの状態 \mathbf{C}_{t-1} と忘却ゲートの出力 \mathbf{f}_t の積の和となる。忘却ゲートの出力は \mathbf{x}_t , h_{t-1} 、バイアスによって求められる。そして、メモリユニットの出力 \mathbf{h}_t は $\tanh(\mathbf{C}_t)$ と出力ゲートの出力 \mathbf{o}_t のアダマール積となる。出力ゲートの出力は \mathbf{x}_t , h_{t-1} , \mathbf{C}^t 、バイアスによって求められる。

本論文においては、LSTM の重み更新式として RMSprop [4] を用いている。RMSprop は再帰型ニューラルネットワークにおいて定評のある重み更新アルゴリズムであり、以下の式で定義される。

$$\begin{aligned} h_t &= \alpha h_{t-1} + (1 - \alpha) \nabla E(\mathbf{w}^t)^2 \\ \eta_t &= \frac{\eta_0}{\sqrt{h_t + \epsilon}} \\ \mathbf{w}^{t+1} &= \mathbf{w} - \eta_t \nabla E(\mathbf{w}^t) \end{aligned} \quad (7)$$

ここで、 w は更新する重みであり、 $E(\cdot)$ は誤差関数を表している。そして $\nabla E(\cdot)$ は誤差関数の勾配を表している。 η が学習率である。本実験においては $\eta = 0.001$ に設定している。

3 実験

本節では、法人企業統計調査による企業の投資率および関連する指標の回帰分析に関する実験を行う。投資率と、その説明変数とする各財務比率との間の相関関係を調べるための実験設定として、時刻 $t+1$ における設備投資率を時刻 t における各財務比率を用いたニューラルネットワークによる回帰分析を行う。その際に、回帰に用いる説明変数の数および種類を変化させ、設備投資率の予測に対して有効な説明変数を推定する。最後に、各結果について評価する。本章において、説明変数の数を変化させる実験設定を特徴選択と呼ぶ。

3.1 データセット

本研究では、統計法に基づく基幹統計として「法人企業統計調査規則」(昭和 45 年大蔵省令 48 号)に基づいて、財務省により収集された法人企業統計調査を使用した。この調査は、営利法人等を調査対象とし、その中から無作為抽出により標本法人を選定している。総企業数は年次、および四半期別に異なるが 20000 社ほどとなっている。四半期別調査票データと年次別調査票データが存在し、本研究では一般業の四半期別調査票データの 2003 年 1 期から 2016 年 4 期までの 14 年間、56 期分のデータを使用している。まず 20000 社の内で対象の 14 年間の内に倒産またはその他の理由により調査対象から外れたものを除外した結果、対象の企業数は 2432 社となった。

法人企業統計には調査項目として、前期および当期における資本金や売上高、負債等を示した各企業の財務状況が報告されている。それらの企業のデータを用いて、種々の財務比率を算出し、説明変数として用いる。しかし、調査データにおいて多くの欠測値があり、算出することが困難な指標が多く存在した。したがって今回の実験においては、対象企業数全体の 50% 以上が欠測している財務比率については使用していない。過半数が欠測しているデータに関しては、その後補完処理を行ったとしても真の系列データとは大きく乖離していることが考えられるためである。財務比率を算出した際に 0 での除算などが発生した財務報告がなされている企業を除外した結果、最終的に実験に用いた企業数は 2330 社となった。最終的に実験に用いる欠測値を含む指標については、後述の補完処理を行い使用し

ている。結果として、本研究において実際に使用している財務比率を示す。また以降はそれぞれの財務比率について以下に示すように $V1 - V12$ と呼ぶとする。

- V1: 総資本営業利益率
- V2: 総資本経常利益率
- V3: 売上高営業利益率
- V4: 売上高経常利益率
- V5: 総資本回転率
- V6: 有形固定資産回転率
- V7: 買掛金回転期間
- V8: 減価償却費
- V9: 労働装備率
- V10: キャッシュフロー率
- V11: 設備投資率
- V12: 総資本利益率 (ROA)

ここで、各財務比率は法人企業統計における財務営業比率の算式²を参考としている。また、キャッシュフロー率については以下の式で定義されている。

$$\text{キャッシュフロー率} = \frac{\text{当期純利益} + \text{減価償却費}}{\text{総資本}} \times 100 \quad (8)$$

3.1.1 データの補完処理

統計調査において、無回答や無記入により調査項目の一部の情報が得られない場合に欠測値が生じる。欠測を含むデータにおいて、観測された値のみを用いて推定を行う場合、欠測バイアスが生じることや、推定精度への悪影響が考えられる。また本研究で用いている、法人企業統計調査においても多くの欠測値が認められ、観測されているデータのみを用いて分析を行うことは困難であり補完処理を行うことが必要であった。また Table 1 に今回用いた企業データについて詳細を示す。補完処理については年次別データを用いて行った。四半期単位の財務指標の時系列 g_t において、四半期 j の値が欠測しているとする。その際には g_t と対応する、年次単位の財務指標の時系列 G_t を参照し、四半期 j が含まれる年次 J の値 G_J を用いる。

²<http://www.mof.go.jp/pri/reference/ssc/results/calculation.htm>

表 1: Overview of raw dataset.

	Missing ratio[%]	AVE±STD
V1	0.03	0.010±0.029
V2	0.03	0.011±0.027
V3	0.04	0.031±0.654
V4	0.04	0.036±0.724
V5	0.04	0.275±0.242
V6	20.17	4.201±65.320
V7	6.41	6.828±39.400
V8	2.28	0.041±0.038
V9	20.25	57.499±498.640
V10	2.69	0.062±0.066
V11	7.04	0.008±0.028
V12	1.14	0.056±0.071

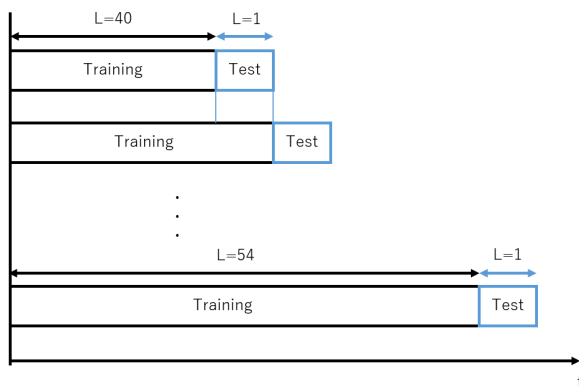


図 3: Overview of Experiment.

3.2 実験設定

財務指標間の関係性について、ある時刻 t の説明変数に当たる財務指標と時刻 $t+n$ における被説明変数に当たる財務指標への回帰タスクを行い結果を評価する。本論文では $n=1$ と設定し、1 時刻隔てた変数間の相関関係を考察する。比較実験として ARIMA モデルを用いた自己回帰を行い結果を比較する。学習期間として、40 期分のデータを与える実験から 54 期分のデータを入力として与え、その一つ先の期における被説明変数を予測する実験を行う。よって時間方向に 15 通りの実験を行い、予測対象の四半期の違いによる予測難易度の変化の比較実験もまた行った。概要を図 3 に示す。

予備実験は、本実験で時刻 t のデータから時刻 $t+1$ における被説明変数に対する予測を行う実験設定においては時刻 $t-1$ のデータから時刻 t における被説明変数の予測を行う実験設定を予備実験とし、超パラ

メータの最適化を行った。探索範囲は中間層の数 L については $L \in \{1, 2, 3\}$ 、ユニット数 U については $U \in \{25, 50, 75, 100, 125\}$ である。なお、 L については、全ての説明変数を用いた実験設定において $L \in \{1, 2, 3, 4, 5\}$ について実験を行ったが、探索した範囲において最適な値が $L=2$ となった。したがって、その他の説明変数の数を減じた実験設定においては $L \in \{1, 2, 3\}$ において行った。この実験設定においては、全財務比率を用いた実験およびキャッシュフロー比率のみを除外した実験についての予備実験を行い、そこで設定した超パラメータにより本実験を行った。その他の超パラメータについては、エポック数を 100、学習率を 0.001、バッチサイズを 10 に設定して実験を行った。

4 実験結果

結果を表 2, 図 4 に示す。それぞれの結果は学習期間が 40-54 の 15 種類の実験を行い、その MSE の平均値を示している。ARIMA モデルについては 40 期分のデータよりモデルを学習し、残りの四半期について予測を行った。本実験においてはキャッシュフロー比率を除外した実験において結果の悪化が確認された。来期の予測問題において、内部資金の利用可能性が設備投資の水準に作用しているという仮定に対して矛盾のない結果が観察された。

また、次に予測対象の四半期について注目した結果を表 3 に示す。これより、1-3 月の第 4 四半期の予測において誤差が大きい結果となった。これは、年度末における財務指標とその他の四半期における財務指標とで傾向が大きく異なっていることが考えられる。また財務分析において、どの期におけるデータかを示すダミー変数を追加することによって結果の向上を見込むことが考えられる。

5 おわりに

本論文では、企業の財務報告である法人企業統計に対して、設備投資率に対するその他の財務比率の相関を確認するために、LSTM を用いた回帰分析およびその比較手法として ARIMA モデルを用いて分析を行った。特定の財務比率を説明変数から除外することにより、相対的にその財務比率の影響力を評価することができると考えられる。特に設備投資率とキャッシュフロー比率との間の依存性に関心がある。実験では 1 時刻の先の被説明変数との分析を行い、結果として仮説と矛盾のない結果が示された。

今後の展望として、よりデータに則した処理を行うことが考えられる。例えば、説明変数に四半期の季節性を考慮したダミー変数を考慮することや、リーマン

表 2: Result of Experiment in the task of estimating the financial ratio of hidden companies in the one time step ahead.

Excluded financial ratio	MSE
V1	4.25E-04
V2	4.32E-04
V3	4.28E-04
V4	4.20E-04
V5	4.29E-04
V6	4.32E-04
V7	4.23E-04
V8	4.38E-04
V9	4.11E-04
V10	4.28E-04
Nothing excluded	4.20E-04
ARIMA	6.50E-04




図 4: Result of Experiment in the task of estimating the financial ratio of hidden companies in the one time step ahead.

表 3: Quarterly Average Result of Experiment.

Target period	MSE
1(April-June)	4.02E-04
2(July-September)	3.15E-04
3(October-December)	2.94E-04
4(January-March)	6.88E-04

ショックなど大きな事件が起こったことを表す変数を追加することが考えられる。経済データは社会動向により大きく変動することが考えられ、過去の系列情報だけでなく外因を考慮する必要があると考えられるからである。次に LSTM ネットワークについてもより最適化が可能であると考えられる。今回着目しなかった超パラメータについて最適化を行うことや、モデルの構造においてはシーケンス予測のための多くのアーキテクチャが提案されており今回のデータセットに対してより適切なアーキテクチャが存在している可能性がある。また深層構造を伴うネットワークを扱う際には、事前学習として Deep Belief Network を用いて事前学習を行うことなどにより性能の向上が期待できる。

謝辞

本研究の一部は科学研究費補助金基盤研究 (B)(15H02703) の援助による。

参考文献

- [1] T. Mikolov, M. Karafiat, L. Burget, J. Cernocky, and S. Khudanpur.: Recurrent neural network based language model, *Proceedings of the Annual Conference of International Speech Communication Association*, pp. 1045–1048, (2010)
- [2] Sepp Hochreiter and Jurgen Schmidhuber.: Long short-term memory, *Neural computation*, pp. 1735–1780, (1997)
- [3] Hasim Sak, Andrew Senior, and Franc, oise Beaufays.: Long short-term memory recurrent neural network architectures for large scale acoustic modeling, *Proceedings of the Annual Conference of International Speech Communication Association*, (2014)
- [4] Geoffrey Hinton.: Neural Networks for Machine Learning - Lecture 6a - Overview of mini-batch gradient descent.(2012)
- [5] 桜井久勝, 森脇敏雄. : 財務比率による倒産リスク評価の有効性, *Discussion Paper Series*, (2016)
- [6] 嶋恵一. : 内部資金と投資 法人企業統計による企業規模別分析, 財務省財務総合政策研究所「フィナンシャル・レビュー」平成 29 年第 2 (通巻第 130 号), (2017)

- [7] 花崎正春, 羽田徹也. : 企業の投資行動の決定要因分析 投資の多様化の進展と内部資金の役割, 財務省財務総合政策研究所「フィナンシャル・レビュー」平成 29 年第 4 号 (通巻第 132 号), (2017)
- [8] 沖本竜義.: 経済・ファイナンスデータの計量時系列分析, 朝倉書店, (2010)