

[Original article]

(2020年4月7日 Accepted)

ベイズ統計に基づく深層学習による株価予測に関する一考察

前田 康成¹

1) 北見工業大学・地域未来デザイン工学科

要約：近年、株価予測について多く研究されている。従来研究では予測対象銘柄の学習データが利用されている。しかし、現実には予測対象銘柄の学習データが存在しないことも多い。そこで、本研究ではベイズ統計に基づいて予測対象銘柄以外の既存データを学習データとして利用する。従来研究では全結合ニューラルネットワークを用いた深層学習を株価予測に適用している。本研究では、ベイズ統計に基づく全結合ニューラルネットワークを用いた深層学習を株価予測に適用する。本研究は従来研究のベイズ統計の視点による拡張研究の一環である。新しい予測方法を提案し、株価予測実験と投資シミュレーションの結果を紹介する。投資シミュレーションの結果に基づいて提案方法の有効性を確認する。

キーワード：株価予測、深層学習、ベイズ統計、全結合ニューラルネットワーク、投資シミュレーション

A Note on Stock Price Prediction by Deep Learning based on Bayesian Statistics

Yasunari MAEDA¹

1) School of Regional Innovation and Social Design Engineering, Kitami Institute of Technology

Abstract: Much research in recent years has focused on stock price prediction. In previous research learning data of a prediction target company is used. However, there is not learning data for the prediction target company often in the real world. In this research existing data of other companies is used as learning data based on Bayesian statistics. In previous research deep learning by fully connected neural networks is applied to predict stock price. In this research deep learning by fully connected neural networks based on Bayesian statistics is applied to predict stock price. This research is one of the extended research of the previous research from the viewpoint of Bayesian statistics. A new prediction method is proposed. Results of some stock price prediction experiments and investment simulations are shown. The effectiveness of the proposed method is shown by the results of the investment simulations.

Keywords: stock price prediction, deep learning, Bayesian statistics, fully connected neural networks, investment simulation

Yasunari MAEDA

165 Koen-cho, Kitami-shi, Hokkaido, 090-8507, Japan

Phone: +81-157-26-9328, Fax: +81-157-26-9344, E-mail: maedaya@mail.kitami-it.ac.jp

1. はじめに

本研究では、ベイズ統計に基づく全結合ニューラルネットワークによる深層学習[1]を用いた株価予測を扱う。

株価予測には従来から深層学習などの各種機械学習手法が適用されており、株価の上昇下降の2択の予測（2値分類）に対する50%～70%程度の精度の報告が多い[2][3]。株価予測ではなく、投資そのものへの深層強化学習、遺伝的ネットワークプログラミングなどの各種機械学習手法の適用例も報告されている[4][5]。

株価予測の主な目的の一つは、予測結果の投資への適用である。従来研究[6]では、全結合ニューラルネットワークによる深層学習を用いた株価の予測方法を提案し、その予測結果を投資シミュレーションに適用することにより、提案方法の有効性を検証している。

深層学習に限らず、機械学習では学習データが必要である。株価予測であれば、予測対象銘柄の学習データが必要である。しかし、現実の世界では新規銘柄が株式市場に上場された場合など、何らかの理由で予測対象銘柄の学習データが利用できない場合がある。しかし、学習データが使用できない場合の株価予測に関する検討はほとんど見掛けない。

そこで、本研究では何らかの理由で予測対象銘柄の学習データが利用できない場合に、他の銘柄の学習データをベイズ統計の考え方に基づいて利用する。本研究では、予測対象銘柄以外の複数銘柄の学習データ（学習済モデル）を利用する。予測および学習の基本部分には従来研究[6]の提案方法を利用する。よって、本研究はベイズ統計に基づいて従来研究[6]を予測対象銘柄の学習データが利用できない場合に拡張した拡張研究に相当する。

以下、本研究は従来研究の拡張研究であるため2章で従来研究で扱う予測問題、3章で従来研究で提案された全結合ニューラルネットワークによる予測方法を説明する。4章で本研究のベイズ統計に基づく予測方法を提案する。5章では、提案方法の有効性を検証するために提案方法と従来方法による株価予測の実験結果と投資シミュレーション結果を示し、6章で考察を述べる。最後に7章でまとめと今後の課題について述べる。

2. 従来研究[6]で扱う予測問題

本研究はベイズ統計に基づく従来研究[6]の拡張研究に相当するため、ここでは従来研究で扱う予測問題を説明する。

前日の始値を p_o 、前日の高値を p_h 、前日の安値を p_l 、前日の終値を p_c 、当日の始値を p_o 、当日の終値を p_c とす

る。従来研究では、前日の高値始値比 $r'_{ho} = \frac{p_h}{p_o}$ 、前日の安値始値比 $r'_{lo} = \frac{p_l}{p_o}$ 、前日の終値始値比 $r'_{co} = \frac{p_c}{p_o}$ 、当日から前日にかけての始値終値比 $r'_{oc} = \frac{p_o}{p_c}$ を利用して、当日の終値始値比 $r_{co} = \frac{p_c}{p_o}$ を予測する。ただし、各比を連続値で扱うのではなく、表1のように離散化する。表1中の $d(\cdot)$ は離散化後の値である。 $d(r'_{ho})$, $d(r'_{lo})$, $d(r'_{co})$, $d(r'_{oc})$ を入力として、当日の終値始値比 r_{co} の離散化後の予測値 $\hat{d}(r_{co})$ を出力する。予測値 $\hat{d}(r_{co})$ は表1の $d(r'_{co})$ 同様に1, 2, 3または4の値をとる。各種比の離散値を入出力値とする点が従来研究の予測方法の特徴である。

表1. 離散化

離散化	範囲	$X_i = 1$ の <i>i</i>
$d(r'_{ho}) = 1$	$r'_{ho} = 1.0$	1
$d(r'_{ho}) = 2$	$1.0 < r'_{ho} \leq 1.005$	2
$d(r'_{ho}) = 3$	$1.005 < r'_{ho}$	3
$d(r'_{lo}) = 1$	$r'_{lo} \leq 0.995$	4
$d(r'_{lo}) = 2$	$0.995 < r'_{lo} \leq 1.0$	5
$d(r'_{co}) = 1$	$r'_{co} \leq 0.995$	6
$d(r'_{co}) = 2$	$0.995 < r'_{co} \leq 1.0$	7
$d(r'_{co}) = 3$	$1.0 < r'_{co} \leq 1.005$	8
$d(r'_{co}) = 4$	$1.005 < r'_{co}$	9
$d(r'_{oc}) = 1$	$r'_{oc} \leq 0.995$	10
$d(r'_{oc}) = 2$	$0.995 < r'_{oc} \leq 1.0$	11
$d(r'_{oc}) = 3$	$1.0 < r'_{oc} \leq 1.005$	12
$d(r'_{oc}) = 4$	$1.005 < r'_{oc}$	13

3. 従来研究[6]における全結合ニューラルネットワークによる予測方法

本研究はベイズ統計に基づく従来研究[6]の拡張研究に相当するため、ここでは従来研究で提案された全結合ニューラルネットワークによる予測方法を説明する。

従来研究では入力層、中間層（2層）、出力層の4層構造の全結合ニューラルネットワーク（図1）を用いる。 X_i は入力層の*i*番目のユニットの入力値かつ出力値である。入力層のユニットは、表1の各離散値ごとに設定し、13個用意する。 X_i の値は、離散化された値で決まり、例えば前日の高値始値比 r'_{ho} について範囲 $1.0 < r'_{ho} \leq 1.005$ の場合は、表1より $X_2 = 1$ とする。また、他の比 r'_{lo} , r'_{co} ,

r'_{oc} それぞれについても範囲に従って決まり、該当する離散値がない入力値 X_i は0とする。

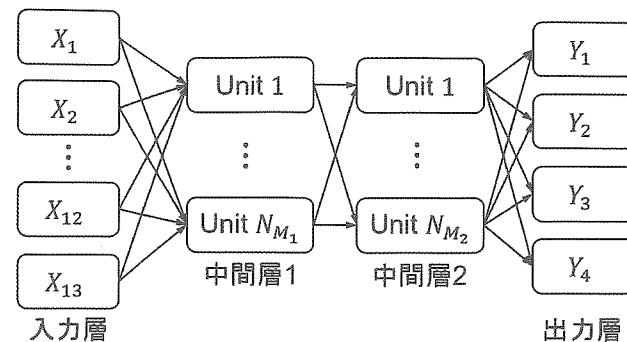


図1. 全結合ニューラルネットワーク

$I_i^{M_k}$ は中間層 k 層目の*i*番目のユニットの入力値で次式による。

$$I_i^{M_k} = \sum_{j=1}^{N_{M_{k-1}}} w_{i,j}^{M_k} O_j^{M_{k-1}} + b_i^{M_k}, \quad (1)$$

ただし、 $O_j^{M_0} = X_j$ 、 $N_{M_{k-1}}$ は前の層の出力値の数、 $w_{i,j}^{M_k}$ は中間層 k 層目の*i*番目のユニットにおける前層の*j*番目のユニットの出力 $O_j^{M_{k-1}}$ に対する重み、 $b_i^{M_k}$ は中間層 k 層目の*i*番目のユニットにおけるバイアスである。

$O_i^{M_k}$ は中間層 k 層目の*i*番目のユニットの出力値で次式による。

$$O_i^{M_k} = f_{M_k}(I_i^{M_k}), \quad (2)$$

ただし、 $f_{M_k}(I_i^{M_k})$ は入力値 $I_i^{M_k}$ を出力値 $O_i^{M_k}$ に変換する中間層 k 層目の活性化関数である。従来研究では中間層の活性化関数として、次式によるシグモイド関数を利用する。

$$f_{M_k}(I_i^{M_k}) = \frac{1}{1+e^{-I_i^{M_k}}}. \quad (3)$$

I_i^0 は出力層の*i*番目のユニットの入力値で次式による。

$$I_i^0 = \sum_{j=1}^{N_{M_2}} w_{i,j}^0 O_j^{M_2} + b_i^0, \quad (4)$$

ただし、 N_{M_2} は中間層2層目の出力値の数、 $w_{i,j}^0$ は出力層の*i*番目のユニットにおける中間層2層目の*j*番目のユニットの出力 $O_j^{M_2}$ に対する重み、 b_i^0 は出力層の*i*番目のユニットにおけるバイアスである。

Y_i は出力層の*i*番目のユニットの出力値で次式による。

$$Y_i = f_O(I_i^0), \quad (5)$$

ただし、 $f_O(I_i^0)$ は入力値 I_i^0 を出力値に変換する出力層の活性化関数で、従来研究ではソフトマックス関数を利用する。

$$f_O(I_i^0) = \frac{e^{I_i^0}}{\sum_j e^{I_j^0}}. \quad (6)$$

Y_i は当日の終始比 r_{co} の離散化後の値が*i*である確率と解釈できる。当日の終始比 r_{co} の離散化後の予測値 $\hat{d}(r_{co})$ は次式による。

$$\hat{d}(r_{co}) = \arg \max_i Y_i = \arg \max_i f_O(I_i^0), \quad (7)$$

入力層の入力値(状態)に対して、式(1)、式(2)、式(4)、式(5)、式(7)を用いることによって、全結合ニューラルネットワークの最終的な出力値(当日の終始比 r_{co} の離散化後の予測値 $\hat{d}(r_{co})$)が得られる。

上記の全結合ニューラルネットワークの学習にはさまざまな学習アルゴリズムが適用できる。従来研究[6]では、学習アルゴリズムとして二乗誤差に対する誤差逆伝播法を適用した場合が報告されている。

4. 本研究における事後確率の更新と予測

本研究では、何らかの理由で予測対象銘柄の学習データが利用できない場合に、他の銘柄の学習データ(他の銘柄の学習データを使用した学習済モデル)をベイズ統計の考え方に基づいて利用する。本研究はベイズ統計に基づく従来研究[6]の拡張研究に相当する。ここでは事後確率の更新と予測について説明する。なお、本研究における予測の基本は3章で解説した従来研究の予測方法である。

最初に事前確率 $\text{Pr}(\text{銘柄}i)$ を導入する。これは、予測対象の銘柄をその他の銘柄の重み付けで表現するための重みに相当する。事前確率の設定の仕方についてはいろいろな考え方があるが、事前に何も情報がない場合には等確率の設定などがよく使用される。ここで、予測対象銘柄に関する新たな入力データに対して予測対象以外の各銘柄に対する学習済のニューラルネットワークを用いて予測した際に、正解(真の終始比 r_{co} の離散化後の値 $d(r_{co})$)が*i*番目のユニットの出力値相当だった場合を考える。この場合の銘柄*k*の事後確率 $\text{Pr}(\text{銘柄}k)$ (事前確率を更新したもの)は次式で計算する。

$$\text{Pr}(\text{銘柄}k) = \frac{\text{Pr}(\text{銘柄}k) f_O(I_i^0)_k}{\sum_j \text{Pr}(\text{銘柄}j) f_O(I_i^0)_j}. \quad (8)$$

ただし、 $f_O(I_i^0)_k$ は銘柄*k*の学習済モデルによる出力である。なお、式(8)の右辺の分母では学習データが存在しない予測対象銘柄を除く、学習データが存在する(学習済

モデルが存在する) すべての銘柄について合算している。予測対象銘柄に関する新たな入力データと出力データおよび正解データが得られるたびに式(8)によって事後確率を更新することによって、予測対象銘柄についてその他の銘柄の学習済モデルの組合せによる学習を進めることができる。逐次的に式(8)を使用する際には、直前の事後確率を式(8)右辺の事前確率に代入する。

本研究では、予測対象以外の銘柄(学習済モデル)の事前確率(または更新前の事後確率)で出力値を重み付けて、次式で当日の終値始値比 r_{co} の離散化後の予測値 $\hat{d}(r_{co})$ を算出する。

$$\hat{d}(r_{co}) = \arg \max_i \sum_j \Pr(\text{銘柄}j) f_o(I_i^0)_j, \quad (9)$$

5. ベイズ統計に基づく予測結果と投資シミュレーション結果

提案方法による株価の予測実験と投資シミュレーションの結果を報告し、提案方法の有効性について6章で考察する。株価の予測結果を表2と表3に示す。表2は予測対象の銘柄の学習データを使用した従来方法[6]で、表3が何らかの理由で予測対象銘柄の学習データが使用できず、ベイズ統計に基づいて予測対象以外の銘柄の学習データを使用した提案方法である。予測対象以外の銘柄の事前確率は等確率に設定した。

2009年～2016年のデータで学習、2018年のデータで評価を行った。学習には、従来研究[6]と同様に二乗誤差に対する誤差逆伝播法を5000回繰返して適用した。表2および表3中の値は5000回の学習による学習済ニューラルネットワークを10組用意して評価した平均値(小数点以下第3位を四捨五入)である。中間層のユニット数はすべて10とした。

表2および表3中のAが前述の $d(r'_{ho})$, $d(r'_{lo})$, $d(r'_{co})$, $d(r'_{oc})$ を入力とする場合である。BとCは追加で、それぞれ $d(r'_{ho})$, $d(r'_{co})$, $d(r'_{oc})$ を入力とする場合(入力層のユニット数は11)と $d(r'_{co})$, $d(r'_{oc})$ を入力とする場合(入力層のユニット数は8)である。適切な入力情報に関する検討に資する実験データ入手するために、入力情報を削減したBとCを追加した。5000回の繰返し学習にはJavaで作成したプログラムを使用し、Windows10 Pro 64ビットOS, CPU2.70GHz, メモリ12.0GBの計算機で表3中のAの場合で約1分を要した。4択が予測値 $\hat{d}(r_{co})$ と真の $d(r_{co})$ の正解率で、2択が株価の上昇下降の正解率(離散化後の1と2を下降クラス、3と4を上昇クラスと解釈した場合の正解率)である。

表2. 予測結果(当該銘柄の学習データ使用(従来方法))(正解率%)

銘柄	A4択	A2択	B4択	B2択	C4択	C2択
1	36.12	52.07	35.17	51.32	35.25	51.28
2	32.23	55.21	30.04	52.89	28.31	55.08
3	32.60	53.72	32.56	53.76	32.69	53.93
4	37.64	53.10	38.80	53.35	38.72	54.09
5	27.69	49.05	29.01	50.54	28.39	50.12
6	26.03	48.47	24.46	47.56	24.75	47.52
7	28.26	47.60	27.52	46.49	26.74	44.67
8	28.39	50.79	27.89	48.93	28.02	49.01
9	31.65	54.21	30.62	52.27	32.27	52.48
10	30.25	52.81	32.07	55.12	34.21	55.83
11	34.96	53.35	34.88	53.14	33.68	49.63
12	34.13	50.00	34.13	50.08	33.26	48.88
平均	31.66	51.70	31.43	51.29	31.36	51.04

表3. 予測結果(当該銘柄の学習データ不使用(提案方法))(正解率%)

銘柄	A4択	A2択	B4択	B2択	C4択	C2択
1	33.22	52.27	34.59	54.09	36.49	55.50
2	32.89	49.92	33.88	51.40	32.52	47.85
3	30.50	53.88	30.08	53.51	30.62	54.63
4	37.27	52.89	37.11	52.64	36.94	53.22
5	29.71	50.58	30.17	50.33	29.92	48.02
6	29.79	56.61	31.90	58.47	29.42	58.26
7	34.17	53.64	34.13	53.97	33.60	53.26
8	30.91	50.99	30.12	50.12	29.17	47.27
9	32.07	50.45	30.99	48.93	32.60	51.74
10	30.50	49.92	30.29	49.96	29.75	51.90
11	36.32	57.23	37.23	58.18	35.87	55.45
12	38.06	54.63	37.98	53.72	37.73	53.06
平均	32.95	52.75	33.21	52.94	32.89	52.51

表4にデータとして利用した銘柄を示す。利用銘柄の選択は著者の主観による。株価予測の一般的な目的の一つは投資運用への応用であるため、従来研究[6]と同様に投資シミュレーションに応用した結果を表5と表6に示す。表5は投資対象銘柄の学習データを使用した従来方法による予測結果を投資シミュレーションに適用した結果で、表6が何らかの理由で投資対象銘柄の学習データが使用できず、ベイズ統計に基づいて投資対象以外の銘柄の学習データを使用した提案方法による予測結

果を投資シミュレーションに適用した結果である。

本研究の投資シミュレーションでは、従来研究[6]と同様に毎回100万円を投資するデイトレード（当日の始値で購入して当日の終値で決済）を実施している。2009年～2016年のデータで学習済の予測モデルによる予測結果を用いた、2018年の投資シミュレーション結果である。 r_5 は予測値 $\hat{d}(r_{co})$ が4 ($r_{co} > 1.005$ と予測) の場合に投資するデイトレードをした場合の1年間の利益（万円）を示す。 r_0 では投資基準を予測値 $\hat{d}(r_{co})$ が3または4 ($r_{co} > 1.0$ と予測) の場合とした。表2、表3同様に10組の平均値（小数点以下第2位を四捨五入）である。

表4. 銘柄

銘柄1	日本ハム(株)
銘柄2	武田薬品工業(株)
銘柄3	パナソニック(株)
銘柄4	ソニー(株)
銘柄5	カシオ計算機(株)
銘柄6	三菱重工業(株)
銘柄7	マツダ(株)
銘柄8	伊藤忠商事(株)
銘柄9	住友商事(株)
銘柄10	三菱商事(株)
銘柄11	(株)三井住友フィナンシャルグループ
銘柄12	(株)NTTデータ

表5. 投資シミュレーション結果（当該銘柄の学習データ使用（従来方法））（万円）

銘柄	Ar5	Ar0	Br5	Br0	Cr5	Cr0
1	4.7	4.7	2.2	2.2	-0.8	-0.8
2	5.8	6.0	-10.0	-9.9	3.1	3.1
3	-0.9	-0.9	-0.4	-0.4	-0.6	-0.6
4	5.9	5.9	10.6	10.6	13.8	13.8
5	8.3	8.3	13.6	13.6	10.3	10.3
6	-10.7	-10.7	-14.4	-14.4	-14.1	-14.1
7	8.1	8.1	6.2	6.2	2.5	2.5
8	6.1	5.9	2.5	2.4	2.6	2.6
9	5.4	7.0	3.8	6.1	5.8	7.4
10	-0.9	-0.7	4.4	4.7	8.1	8.1
11	-0.8	-0.9	-2.4	-2.4	-5.3	-5.3
12	-7.0	-7.0	-7.2	-7.2	-8.6	-8.6
平均	2.0	2.1	0.7	1.0	1.4	1.5

表6. 投資シミュレーション結果（当該銘柄の学習データ不使用（提案方法））（万円）

銘柄	Ar5	Ar0	Br5	Br0	Cr5	Cr0
1	-1.7	-1.7	3.6	3.5	3.5	3.5
2	-19.9	-19.9	-19.1	-19.4	-23.4	-23.4
3	-4.2	-4.2	-3.3	-3.3	-6.3	-6.3
4	5.5	5.5	4.1	4.1	8.2	8.2
5	14.0	14.0	14.9	14.9	11.9	11.9
6	9.3	9.3	15.9	15.9	12.2	12.2
7	24.4	24.4	24.9	24.9	23.8	23.8
8	9.0	9.5	9.7	9.8	3.8	3.3
9	-1.4	-1.4	-4.3	-4.3	-0.4	-0.4
10	2.1	2.1	1.8	1.8	7.6	7.6
11	4.0	3.9	2.6	2.6	1.9	1.9
12	11.7	11.7	7.7	7.7	7.4	7.4
平均	4.4	4.4	4.9	4.9	4.2	4.1

6. 考察

最初に、予測対象銘柄の学習データを用いた従来方法（学習および予測）による予測結果の表2と、予測対象の銘柄以外の11銘柄の学習データを用いた本研究の提案方法（学習および予測）による予測結果の表3を比較する。予測対象の12銘柄全体での平均（各表の最下部）を比較すると提案方法の方が少し正解率が高い。しかし、差は小さく、従来方法も提案方法も4択の予測で3割程度、2択の予測で5割程度と総じて高い精度ではない。

次に、予測対象銘柄の学習データを用いた従来方法（学習および予測）による予測結果を投資シミュレーションに適用した表5と、予測対象銘柄以外の11銘柄の学習データを用いた本研究の提案方法（学習および予測）による予測結果を投資シミュレーションに適用した表6の投資シミュレーション結果を比較する。予測対象の12銘柄全体での平均（各表の最下部）を比較すると、提案方法では対象の1年間で4万円以上の利益があるのに対して、従来方法の利益は1万円から2万円程度であり、提案方法の方が平均的に利益が高い傾向にある。

以上より、予測対象銘柄の学習データを用いた従来研究の予測方法と同様に、予測対象以外の銘柄の学習データを用いる本研究の提案方法も予測精度は高くない。しかし、予測結果を投資シミュレーションに適用した場合には、本研究の提案方法は従来研究の予測方法と同程度かそれ以上の利益が期待できることが確認できた。投資シミュレーションにおいて従来方法よりも高い利益が

出したケースでは、予測対象銘柄以外の11銘柄の学習データを事後確率で重み付けしたものと予測対象銘柄の評価データ（2018年）間の類似性が、予測対象銘柄の学習データと評価データ間の類似性よりも高かったことが想像される。しかし、どのような類似度／距離で測定した類似性が投資シミュレーション結果に影響するのかが不明である。また、仮に使用すべき類似度／距離が明確になつても投資の事前には評価データは未知である。よって、予測対象銘柄以外の学習データとしてどのような銘柄の既存データを利用した場合に従来方法（予測対象銘柄の学習データを利用した場合）よりも高い利益になるのかは現時点では不明である。この点の明確化は今後の課題としたい。

また、適切な入力情報に関する検討に資する実験データ入手するために、入力層のユニット数が13のA以外に入力情報を削減したBとCを追加したが、ABC間での明確な差は確認できなかった。よって、適切な入力情報に関する検討も今後の課題としたい。

7. まとめと今後の課題

従来から株価予測に関する研究は数多く実施されているが、予測対象の株銘柄の大量の履歴データ（学習データ）の利用を前提にする予測方法／学習方法がほとんどである。しかし、新規銘柄の株式市場上場時など、現実には予測対象銘柄の履歴データが存在しない場合も多い。そこで、本研究では、何らかの理由で予測対象銘柄の学習データが利用できない場合に、他の銘柄の学習データ（他の銘柄の学習データを使用した学習済モデル）をベイズ統計の考え方に基づいて利用する株価予測方法を検討した。本研究の提案方法は従来研究[6]の提案方法を基本としており、本研究は従来研究の拡張研究に相当する。

株価の予測実験と予測結果を用いた投資シミュレーションより、本研究の提案方法の予測精度は従来方法[6]と同程度であるのに対して、予測結果を適用した投資については従来方法と同程度かそれ以上の利益が期待できることを確認した。このことは、予測対象の銘柄の履歴データが存在しない場合でも、予測対象以外の銘柄の履歴データが十分に存在すれば投資向けの予測が可能であることを示唆している。

どのような予測対象銘柄以外の銘柄の既存データを提案方法における学習データとして利用するかが投資の成否に大きく依存すると考えられる。予測対象銘柄以外の銘柄の選択方法に関する検討は今後の課題である。

また、従来研究[6]でも指摘されているが、適切な入力情報や各種比の離散化に伴う適切な閾値に関する検討も今後の課題である。

次に本研究内容の健康・医療分野への適用可能性について述べる。本研究では、予測対象以外の銘柄の学習済モデルにベイズ統計に基づいて事前確率／事後確率で重み付けをすることによって、学習データが存在しない予測対象銘柄の株価予測を可能にしている。本研究の基本的な考え方はさまざまなモデルに適用可能である。例えば、従来研究[7]では医療検査項目の選択や医療アドバイスの選択などのヘルスケア支援を表現する確率モデルとしてマルコフ決定過程というモデルを採用している。ヘルスケア支援の場合にも、履歴データが存在しない国／地域／民族に対するヘルスケア支援を実施したいという要望が想定される。このような場合には、本研究のベイズ統計に基づく考え方を適用することが可能だと考える。具体的な検討については今後の課題としたい。

参考文献

- [1] 人工知能学会：深層学習，近代科学社，2015.
- [2] 及川健一郎，堀田政二：機械学習によるFacebookに基づく株価予測，映像情報メディア学会技術報告, Vol.38, No.32, pp.39-40, 2014.
- [3] 宮崎邦洋，松尾豊：深層学習を用いた株価予測の分析，人工知能学会全国大会論文集JSAI2017, 2D3-OS-19a-3, 2017.
- [4] 泉良裕，平澤宏太郎，古月敬之：重要度指標付きGenetic Network Programmingを用いた株式売買モデル，計測自動制御学会論文集, Vol.42, No.5, pp.559-566, 2006.
- [5] GMOインターネット株式会社次世代システム研究室：AIで株をやる！～株の売り買いを深層強化学習で予想，2017. <<https://speakerdeck.com/jisedaiaidezhu-woyaru-zhu-falsemai-rimai-iwoshen-ceng-qiang-hua-xue-xi-deyu-xiang>> (2020年2月21日参照)
- [6] 前田康成：深層学習による株価予測に関する一考察，電子情報通信学会論文誌D, Vol.J103-D, No.4, Apr.2020. 【掲載決定】
- [7] 前田康成，山内翔，鈴木正清，高野賢裕，松嶋敏泰：マルコフ決定過程を用いたヘルスケア支援に関する一考察，バイオメディカル・ファジィ・システム学会誌, Vol.19, No.2, pp.21-27, 2017.

前田康成（まえだやすなり）

平成7年早大・理工卒、平成9年同大学院理工学研究科修士課程修了。日本電信電話（株）、東日本電信電話（株）、北見工大助手、助教、准教授を経て平成28年同大学教授、現在に至る。博士（工学）。
統計的決定理論の学習問題への応用に関する研究に従事。電子情報通信学会等各会員。

