

THE IEICE TRANSACTIONS ON INFORMATION AND SYSTEMS (JAPANESE EDITION)

IEICE | **電子情報通信学会**
D | **論文誌** 情報・システム

VOL. J103-D NO. 4

APRIL 2020

本PDFの扱いは、電子情報通信学会著作権規定に従うこと。

なお、本PDFは研究教育目的（非営利）に限り、著者が第三者に直接配布することができる。著者以外からの配布は禁じられている。

情報・システムソサイエティ

一般社団法人 **電子情報通信学会**

THE INFORMATION AND SYSTEMS SOCIETY

THE INSTITUTE OF ELECTRONICS, INFORMATION AND COMMUNICATION ENGINEERS

深層学習による株価予測に関する一考察

前田 康成[†] (正員)

A Note on Stock Price Prediction by Deep Learning

Yasunari MAEDA[†], Member

[†] 北見工業大学地域未来デザイン工学科, 北見市

School of Regional Innovation and Social Design Engineering, Kitami Institute of Technology, 165 Koen-cho, Kitami-shi, 090-8507 Japan
DOI:10.14923/transinfj.2019JDL8007

あらまし 本研究では, 全結合ニューラルネットワークを用いた深層学習による株価予測について検討する. 予測方法を提案し, その予測結果の有効性を投資シミュレーションによって確認する.

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

1. まえがき

本研究では, 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]. 株価予測の主な目的の一つは, 予測結果の投資への応用だと思われるが, 予測結果の投資への応用に関する報告はほとんどない. 他方, 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].

本研究では, 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, その有効性を検証する. また, 連続値の株価そのものを予測方法の入出力値とせず, 各種比 (前日の高値始値比など) の離散化後の離散値を入出力値とする点も本研究の特徴である.

2. 本研究で扱う予測問題

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. 本研究では, 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 $r'_{oc} = \frac{p_o}{p'_o}$ 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. $d(r'_{ho})$,

表 1 離散化

離散値	範囲	$X_i = 1$ となる 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




図 1 全結合ニューラルネットワーク

$d(r'_{lo})$, $d(r'_{co})$, $d(r'_{oc})$ 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.

各種比の離散値を入出力値とする点が本研究の予測方法の特徴である. なお, 本研究の予測方法は従来研究 [2], [3] の予測方法と優劣を競うものではなく, 各種比の離散値を利用する基本的な予測方法である. 従来研究 [2] では, Facebook などのソーシャル・ネットワーク・サービス (SNS) 上でのテキストデータを入力データとして利用する点が特徴である. 本研究では当日の予測のために当日及び前日のデータを使用するのに対して, 従来研究 [3] では, 過去の多数の株価データ (例えば 100 時点前までの履歴データ) を使用する点が特徴である. これらの従来研究の特徴とともに本研究の予測方法に追加することが可能であり, 追加による改善の可能性に関する検討は今後の課題である.

3. 深層学習による予測方法

本研究では入力層, 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 $\mathbf{X}_2 = 1$ 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 \mathbf{X}_i は 0 とする。

\mathbf{I}_i^{Mk} は中間層 k 層目の i 番目のユニットの入力値である。

$$\mathbf{I}_i^{Mk} = \sum_{j=1}^{N_{M_{k-1}}} w_{i,j}^{Mk} \mathbf{O}_j^{M_{k-1}} + b_i^{Mk}, \quad (1)$$

ただし、 $\mathbf{O}_j^{M_0} = \mathbf{X}_j$, $N_{M_{k-1}}$ は前の層の出力値の数、 $w_{i,j}^{Mk}$ は中間層 k 層目の i 番目のユニットにおける前の層の j 番目のユニットの出力 $\mathbf{O}_j^{M_{k-1}}$ に対する重み、 b_i^{Mk} 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。

\mathbf{O}_i^{Mk} は中間層 k 層目の i 番目のユニットの出力値である。

$$\mathbf{O}_i^{Mk} = f_{Mk}(\mathbf{I}_i^{Mk}), \quad (2)$$

ただし、 $f_{Mk}(\mathbf{I}_i^{Mk})$ は入力値 \mathbf{I}_i^{Mk} を出力値に変換する中間層 k 層目の活性化関数である。本研究では中間層の活性化関数として、式 (3) によるシグモイド関数を用いる。

$$f_{Mk}(\mathbf{I}_i^{Mk}) = \frac{1}{1 + e^{-\mathbf{I}_i^{Mk}}}. \quad (3)$$

\mathbf{I}_i^O は出力層の i 番目のユニットの入力値である。

$$\mathbf{I}_i^O = \sum_{j=1}^{N_{M_2}} w_{i,j}^O \mathbf{O}_j^{M_2} + b_i^O, \quad (4)$$

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

$$\mathbf{Y}_i = f_O(\mathbf{I}_i^O), \quad (5)$$

ただし、 $f_O(\mathbf{I}_i^O)$ は入力値 \mathbf{I}_i^O を出力値に変換する出力層の活性化関数で、ソフトマックス関数を用いる。

$$f_O(\mathbf{I}_i^O) = \frac{e^{\mathbf{I}_i^O}}{\sum_j e^{\mathbf{I}_j^O}}. \quad (6)$$

入力層の入力値 (状態) に対して、式 (1)、式 (2)、式 (4)、式 (5) 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 (当日の終値始値比 r_{co} の離散化後の予測値 $\hat{d}(r_{co})$) が得られる。

4. 予測結果と投資シミュレーション

予測結果を表 2 に示す。日経は日経平均株価 N255、米株は米国の株価指数 S&P500、日立は日立製作所、日ハは日本ハムで、2009 年～2016 年のデータで学習、2017 年～2018 年のデータで評価を行った。学習には、2 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 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全て 10 とした。表 2 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 $d(r'_{ho})$, $d(r'_{co})$, $d(r'_{oc})$ を入力とする場合と $d(r'_{co})$, $d(r'_{oc})$ を入力とする場合である。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 2 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。

株価予測の一般的な目的の一つは投資運用への応用と考えられるため、投資シミュレーションに応用した結果を表 3 に示す。本研究の投資シミュレーションでは、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、2017 年～2018 年の投資シミュレーション結果である。r5 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

表 2 予測結果 (正解率%)

	A4 択	A2 択	B4 択	B2 択	C4 択	C2 択
日経	29.74	50.12	30.53	50.37	29.27	51.08
米株	36.22	51.89	30.50	52.15	31.31	51.89
日立	34.15	55.03	33.76	54.66	33.44	53.80
日ハ	30.98	51.68	31.74	52.27	31.57	52.15

表 3 投資シミュレーション結果 (万円) (記号*は表 3 の r5 と表 5 の em, 表 3 の r0 と表 5 の e05 の比較におけるより大きな利益を示す。)

	Ar5	Ar0	Br5	Br0	Cr5	Cr0
日経	10.3	2.2*	11.2*	3.3*	11.2*	5.8*
米株	3.7*	5.6*	1.7*	9.1*	4.3*	9.5*
日立	7.3*	7.2*	6.5	6.4*	3.2	3.2*
日ハ	2.0	2.3*	5.6*	5.6*	3.3	3.3*

をした場合の2年間の利益(万円)を示す。r0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。なお、N255の日経平均株価、S&P500の米国の株価指数についてもそれぞれ投資対象の銘柄としてシミュレーションを行った。

比較対象を表4、表5に示す。allは予測無しで全日トレードする場合、eは期待効用最大化の考え方に基いて学習データ中の各入力(離散化後の各比の組)に対する平均利益が0よりも大きい場合にトレードしたときの利益(万円)を示す。emは $r_{co} > 1.005$ となる確率が最大の場合にトレードしたときの利益(万円)、e05は $r_{co} > 1.0$ となる確率が0.5よりも大きい場合にトレードしたときの利益(万円)を示す。なお、emとe05のシミュレーションでは学習データ中の各入力(離散化後の各比の組)に対する4事象 $0.995 \geq r_{co}$ 、 $1.0 \geq r_{co} > 0.995$ 、 $1.005 \geq r_{co} > 1.0$ 、 $r_{co} > 1.005$ の頻度データから最ゆう法で推定した各確率の推定値を利用した。

2年間の投資シミュレーション結果なので、各表中の利益を2で除すると1年間の利益率が算出できる。本研究の深層学習による予測結果を利用した表3の1年間の利益率が最小で0.85%、最大で5.6%、3パターンの入力A、B、Cと2パターンの投資基準r5、r0と4銘柄の全組合せに対して正である。このように、表2の深層学習による予測精度は必ずしも高くはないが、投資シミュレーションでは正の利益率が確認できた。

他方、表4、表5による比較対象の各種投資基準のもとでの1年間の利益率は最小で-18.7%、最大で5.3%である。入力パターンA、B、Cと投資基準パターンe、all、em、e05のほとんどの組合せにおいて

表4 その他のシミュレーション結果(1/2)(万円)

	Ae	Be	Ce	all
日経	3.3	2.8	0.2	-9.4
米株	-0.2	0.2	7.6	-6.8
日立	-7.2	1.3	0.8	-37.4
日ハ	-28.9	-9.9	2.2	-20.1

表5 その他のシミュレーション結果(2/2)(万円)(記号*は表3のr5と表5のem、表3のr0と表5のe05の比較におけるより大きな利益を示す。)

	Aem	Ae05	Bem	Be05	Cem	Ce05
日経	10.6*	-5.9	9.4	-5.7	10.5	-5.1
米株	-3.3	-3.5	-6.7	-3.1	1.0	7.6
日立	3.9	-0.5	7.0*	-1.5	5.0*	-4.4
日ハ	2.0	-16.4	4.4	-4.0	7.7*	0.6

負の利益率も確認されている。

本研究の深層学習による株価予測結果を投資に応用した表3の投資基準r5、r0と比較対象の表5の投資基準em、e05は異なる基準であるが類似している。各表を見比べる際には、表2の4択と表3のr5と表5のemの間での比較と、表2の2択と表3のr0と表5のe05の間での比較を実施して頂きたい。表3と表5中の記号*はr5とemまたはr0とe05の間での比較におけるより大きな利益を示す。類似した投資基準間での比較において、本研究における深層学習による株価予測結果を投資に応用した表3の方が頻度データから算出した予測確率に基づく表5よりも利益が大きくなる場合が多かった。

表3、表4、表5には2年間の投資シミュレーションにおける利益を示したが、2年間のシミュレーションにおける投資回数は各シミュレーションによって異なる。よって、2年間の利益が大きいからといって、投資1回あたりの利益率が大きいとは限らない。そこで、1年間の利益率を表6、表7、表8に、1回の投資あたりの利益率を表9、表10、表11に、投資回数(2年間)を表12、表13、表14に示す。表12の投資回数は10組のシミュレーションの平均のため整数ではない。

2年間の利益(表3、表4、表5)と1回の投資あたりの利益率(表9、表10、表11)を比較すると、2年間の利益が大きいかつ1回の投資あたりの利益率も大きなケースもあるが、2年間の利益が大きくても1

表6 表3の1年間の利益率(%)

	Ar5	Ar0	Br5	Br0	Cr5	Cr0
日経	5.15	1.1	5.6	1.65	5.6	2.9
米株	1.85	2.8	0.85	4.55	2.15	4.75
日立	3.65	3.6	3.25	3.2	1.6	1.6
日ハ	1.0	1.15	2.8	2.8	1.65	1.65

表7 表4の1年間の利益率(%)

	Ae	Be	Ce	all
日経	1.65	1.4	0.1	-4.7
米株	-0.1	0.1	3.8	-3.4
日立	-3.6	0.65	0.4	-18.7
日ハ	-14.45	-4.95	1.1	-10.05

表8 表5の1年間の利益率(%)

	Aem	Ae05	Bem	Be05	Cem	Ce05
日経	5.3	-2.95	4.7	-2.85	5.25	-2.55
米株	-1.65	-1.75	-3.35	-1.55	0.5	3.8
日立	1.95	-0.25	3.5	-0.75	2.5	-2.2
日ハ	1.0	-8.2	2.2	-2.0	3.85	0.3

表 9 表 3 の 1 回の投資あたりの利益率 (%)

	Ar5	Ar0	Br5	Br0	Cr5	Cr0
日経	0.108	0.008	0.108	0.011	0.108	0.019
米株	0.034	0.017	0.010	0.029	0.025	0.030
日立	0.047	0.046	0.043	0.042	0.025	0.025
日ハ	0.011	0.012	0.029	0.029	0.019	0.019

表 10 表 4 の 1 回の投資あたりの利益率 (%)

	Ae	Be	Ce	all
日経	0.024	0.026	0.002	-0.019
米株	-0.001	0.001	0.026	-0.014
日立	-0.026	0.005	0.004	-0.076
日ハ	-0.111	-0.051	0.013	-0.041

表 11 表 5 の 1 回の投資あたりの利益率 (%)

	Aem	Ae05	Bem	Be05	Cem	Ce05
日経	0.104	-0.028	0.090	-0.028	0.104	-0.025
米株	-0.037	-0.013	-0.036	-0.011	0.006	0.026
日立	0.022	-0.004	0.040	-0.012	0.030	-0.057
日ハ	0.010	-0.080	0.020	-0.021	0.041	0.003

表 12 表 3 の投資回数 (2 年間)

	Ar5	Ar0	Br5	Br0	Cr5	Cr0
日経	95.5	284.3	103.4	298.1	103.4	302.6
米株	109.2	337.2	170.0	317.5	172.1	313.8
日立	155.0	155.5	151.4	152.5	128.7	128.7
日ハ	192.4	192.7	195.2	195.2	169.4	169.4

表 13 表 4 の投資回数 (2 年間)

	Ae	Be	Ce	all
日経	138	109	98	491
米株	273	275	289	498
日立	277	247	220	489
日ハ	260	195	175	489

表 14 表 5 の投資回数 (2 年間)

	Aem	Ae05	Bem	Be05	Cem	Ce05
日経	102	212	104	204	101	209
米株	89	274	185	276	188	289
日立	178	135	176	128	163	78
日ハ	209	205	219	190	189	166

回の投資あたりの利益率は小さいケースもある。

限られたシミュレーション例ではあるが、本研究における深層学習による株価予測の精度は必ずしも高くはないものの、投資シミュレーションにおいては総じて

て比較対象よりも良好な投資結果が確認できた。

5. むすび

本研究では、前日の終値始値比などの各比を離散化した情報を入力として当日の終値始値比の離散化後の値を予測する、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予測について検討した。

本研究における予測精度は特に高くはないが、予測結果を投資シミュレーションに応用した投資結果を比較対象（予測無しでの投資、期待効用最大化による投資、予測確率に基づく投資）と比較すると、総じて本研究の予測結果に基づく投資結果が良好だった。

しかし、入力情報として使用する比の数が 2 から 4 でどれがよいか（シミュレーションの入力パターン A, B, C のどれがよいか）は、銘柄による差異があり、不明である。また、表 1 による各比の離散化のしきい値は著者が主観的に設定した一例に過ぎない。今後の課題として、適切な入力情報や各比の離散化に伴う適切なしきい値に関する検討、より多くの銘柄での検証などが挙げられる。また、従来研究 [2] や従来研究 [3] で提案されている工夫点を本研究の予測方法に追加することによる改善も今後の課題である。

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/jisedai/aidezhu-woyaru-zhu-falsemai-rimai-iwoshen-ceng-qiang-hua-xue-xi-deyu-xiang> (2019 年 8 月 6 日参照)

(2019 年 8 月 21 日受付, 10 月 28 日再受付,
12 月 17 日早期公開)