

## 株価の予測値を用いた株売買戦略の獲得

著者	渡邊 祐太郎
出版者	法政大学大学院理工学研究科
雑誌名	法政大学大学院紀要. 理工学・工学研究科編
巻	61
ページ	1-4
発行年	2020-03-24
URL	<a href="http://doi.org/10.15002/00022913">http://doi.org/10.15002/00022913</a>

# 株価の予測値を用いた株売買戦略の獲得

Acquisition of stock trading strategy using predicted stock price

渡邊祐太郎

Yutaro Watanabe

指導教員 平原誠

法政大学大学院理工学研究科応用情報工学専攻修士課程

In recent years, stock price prediction and stock trading using machine learning have become useful. In stock trading using machine learning, the present-day stock price is commonly used. However, making a profit from reinforcement learning using this stock price is difficult. Therefore, the aim of this research is to make a profit by performing reinforcement learning using the predicted stock price. The results show that using the predicted stock price can create profits in the Japanese market.

**Key Words** : Neural Networks, Reinforce Learning, Stock Price Prediction

## 1. はじめに

現在機械学習を用いた株価予測や株売買が活発化している[1]. 従来の強化学習を用いた株売買戦略では、より多くの利益を獲得するために深層学習の強化学習への応用や、複数銘柄の売買などアルゴリズムの面で様々な工夫が行われてきた[2]. さらに全所持金で株を購入し、売却時は全ての株を売るといったような単純な売買戦略ではなく、売買株数を柔軟に変化させるといった行動空間の工夫もされている[3]. しかし従来の手法では状態空間の工夫はされておらず、一般的に今日の株価を用いることが多い. そこで本研究では、明日の株価を予測するリカレントニューラルネットワーク(RNN)とその予測値を使って株売買戦略を獲得する強化学習を提案する.

## 2. 本研究で使用した指標

### 2. 1. 日経平均株価

本研究で予測、売買する日経平均株価は、東京証券取引第一部に上場する 1700 社の中から選ばれた、日本を代表する 225 社のダウ平均をとった値であり、TOPIX と並び、日本株の重要な指標である. 本研究ではテクニカル分析で使用される「始値」、「安値」、「高値」、「終値」の 4 つの値を 1 日分の入力とする. ここで予測する値は、日経平均株価の明日の「終値」とする.

### 2. 2. Moving Average (MA)

MA は一定期間の平均価格を線でつないだ移動平均線のこと、株価のトレンドの方向や強弱を見るために用いられるテクニカル指標である. 一般的に短期トレンドとして 5 日移動平均線、中長期トレンドとして 25 日移動平均線がよく用いられる. 例えば 5 日移動平均線は今日

を含めた過去 5 日分の終値を合計し、日数の 5 で割った数値を 1 日ずつずらしながら計算して線をつないだものである.

### 2. 3. Volatility Index (VIX)

VIX 指数とは恐怖指数とも呼ばれ投資家の心理や不安定性を示す数値である. アメリカの大きなイベント前や大きなニュースが出たときに投資家心理をチェックでき、数値が大きくなると、NY ダウの株価暴落の危険が高まっていることになる.

## 3. 提案手法

本手法ではまず RNN を用いて株価の予測を行う. RNN とは前の時刻の中間層の状態と次の時刻の入力とを統合することで、時系列情報を扱えるようにしたネットワーク構造となっている. 時間軸展開すると多層 NN を時間方向につなげたネットワークとみなすことができる. そのため学習に誤差逆伝播法を用いることができる. この学習方法は Back Propagation Through Time (BPTT) と呼ばれる. 次に RNN の予測値を用いて強化学習を行う. Q 学習は強化学習の代表的な手法の一つで教師なし学習の




図 1. 強化学習の枠組み

ひとつである。Q 学習は時刻  $t$  における状態  $s_t$  とその状態  $s_t$  でエージェントがとりうる行動  $a_t$  をセットにした行動価値関数  $Q(s_t, a_t)$  の学習を行う。エージェントは図 1 のようにあらかじめ決められた方策で与えられる行動をとり環境から報酬  $r_{t+1}$  と次の状態  $s_{t+1}$  を観測し、 $Q(s_t, a_t)$  を更新する。

行動は「買う」、「売る」、「ステイ」の 3 種類で、1 日 1 回売買を行う。買う場合は所持金の何% を使って株を購入するかを 5% 単位で表現し、売る場合は所持株の何% を売却するかを 5% 単位で表現する。ただし所持金と所持株数がマイナスになる行動はしない。報酬は株を売却したときのみ与えられ、売却時の株価から購入時の株価を引いたものに、売却株数を乗じた値を報酬とした。状態は明日の株価が今日の株価からいくら変動するかを 0.1% 単位で表現する。

強化学習を行う際、学習データに予測誤差の無い完璧な予測値を用いた学習を行うことができる。一つ目の提案手法として学習データに完璧な予測値を用い、テストデータでは RNN の予測値を用いる手法(完璧-RNN)を提案する。しかしこの手法ではテストデータに予測誤差が含まれるデータを用いるのにもかかわらず学習データには予測誤差が存在しない。これではテストデータの予測誤差に対応できない学習機になってしまうと恐れがある。そこで二つ目の提案手法として学習データに RNN の予測値を使い、テストデータにも RNN の予測値を用いる手法(RNN-RNN)の二つの手法を提案する。

## 4. 実験

### 4. 1. 実験データ

実験データは 2000 年から 2019 年までのデータの中からランダムに 800 日間を取り出し、学習データとして 500 日、テストデータとして 300 日に分割する。さらに検証データとして学習データの中からランダムに 20 日ずつを 2 箇所、計 40 日ずつ取り出す。これを一つのデータセットとし、同様の方法で 10 個のデータセットを用意する。

### 4. 2. RNN による株価予測

株価の予測精度はこの後の株売買に影響する。よってできるだけ予測精度を上昇させておく必要がある。そこで事前に入力の工夫を行った。入力には「始値」、「安値」、「高値」、「終値」の 4 つの株価を 1 日分の入力とし、出力(教師信号)は明日の終値とする。これをコントロール実験とし、入力に MA, ViX, またはその両方を加えて学習を行い、それぞれの予測精度を比較する。また機械学習を用いた株価予測には予測値が実測値を後追いするという問題がある。明日の予測値として今日の実測値をそのまま出力するモデルを Persistence Model(PM)と呼び、このモデルも精度の比較対象とする。精度の比較には平均絶対誤差を用いた。




図 2. 株価予測の結果

ここでの平均絶対誤差とは出力である予測値を  $y^{(d)}(d = 1, \dots, 300)$ 、教師信号である実測値を  $t^{(d)}(d = 1, \dots, 300)$  とすると

$$\frac{1}{300} \sum_{d=1}^{300} |y^{(d)} - t^{(d)}| \quad (1)$$

で表すことができる。

入力日数を 6、中間層の素子数を 30 にしてそれぞれのデータセットに対し 5 回実験を行った。結果の一例を図 3 に示す。図 3 のように 4 つの株価に ViX を追加したものが最も良い精度となった。ViX を入れることで暴落危険度を考慮することができ、株価の大きな変動にも対応できるようになったと考えられる。

よって以下では株価の予測値として RNN への入力を 4 つの株価と ViX としたときに得られる出力とする。

### 4. 3. Q 学習による株売買

1 つのデータセットに対して Persistence Model の出力である「今日の実測値」、学習データとテストデータどちらにも完璧な予測値を用いた「完璧-完璧」、学習機を使用せずランダムに行動する「Random」の 3 種類と提案手法である「完璧-RNN」、「RNN-RNN」の 2 種類を用意し計 5 つの手法で評価を行う。なお「完璧-完璧」はテストデータに完璧な予測値を用いているため、実現不可能な実験であるが、強化学習導入により最高でどれくらい利益を出せるか、上限の目安として実験を行った。初期所持金は 200 万円、初期所持株数は 0 株として実験を行った。評価はテストデータの最終的な所持金で行う。5 つの手法に対し各 5 回ずつ実験を行った。またボンフェローニ法による多重検定を優位水準 5% で行った。data1~10 に対する実験結果を表 1 に示す。表内の数字はテストデータの最終資産の 5 回平均である。実験結果は大きく分けて 2 種類に分類できる。1 つ目は random と提案手法との間に有意差があるもの、2 つ目は random と提案手法の間に有意差がないものに分けられた。それぞれの結果の代表例を図 3 と 4 に示す。図の上側のグラフは各手法の最終資産の平均値であり、赤色の線は初期所持金を示している。図の下側の表はボンフェローニ法による多重比較の結果であり優位水準 5% で有意差があった個所に丸印を付けた。

表 1. 各データの実験結果

	今日の 実測値	Random	完璧- 完璧	RNN- RNN	完璧- RNN
data1	2,226,199	2,259,418	3,120,175	2,641,556	2,500,599
data2	1,835,887	1,793,647	2,672,627	2,050,128	1,921,141
data3	1,917,096	1,868,619	2,832,448	1,991,921	1,963,630
data4	2,017,167	2,041,090	3,005,661	2,519,630	2,064,750
data5	2,842,176	2,387,657	3,582,199	3,111,905	2,249,855
data6	2,002,737	1,910,470	2,671,084	2,229,387	2,155,609
data7	1,882,728	1,948,567	2,737,167	2,333,307	2,168,788
data8	1,552,731	1,645,850	2,462,527	2,019,763	1,839,193
data9	1,898,008	1,793,569	2,765,963	2,246,701	2,179,345
data10	2,162,558	2,121,600	3,424,266	2,563,296	2,395,533

### 5. 考察

RNN の予測値を用いて強化学習（「完璧-RNN」, 「RNN-RNN」）を行えば全てのデータに対して random に行動した場合と今日の实測値を用いた場合よりも多くの利益を上げることができた。このことから明日の株価の予測値を用いて強化学習を行えば利益を出せることがわかる。


しかし data3 と data8 では有意差が見られなかった。data3 と data8 に関してテストデータの期間中どこで利益を出しているか確認した。代表して data8 のテストデータ期間中の利益を図 5 に示す。第 1 軸の青色の線は株を売却した時の利益を示しており、第 2 軸のオレンジ色の線は株価を示している。図から株価が大きく下降したところで大きな損失を出していることがわかる。原因解明のため data8 の株価の変動率のヒストグラムを確認した。学習データのヒストグラムを図 6, テストデータのヒストグラムを図 7 に示す。学習データは株価の変動率のばらつきが少なかったが、テストデータはばらつきが大きいデータであった。このことから学習段階で、株価の変動率が大きな状態を学習がしていないにもかかわらず、テスト時に株価の変動率が大きい状態があったため、大きな損失を出してしまったと考えられる。これを改善するには株価の大きな変動率に対応できるような Q-table の刻みにする必要がある。

追加実験として Q-table の刻みを変動率の大きなものから各状態に 10 個ずつ入るような刻みに変更し、実験を行った。この刻みの変更によりどの状態についても満遍なく学習ができるので、未知のデータであるテストデータに大きな変動率があったとしてもうまく対応できると考えられる。

この時の利益の獲得状況を図 8 に示す。刻みを変更したことで、図 5 と比べて、図 8 の 30 日目付近の株価が大きく下降しているところでも損失を出していないことがわかる。


10 個中すべてのデータセットで「完璧-完璧」と提案手

法である「RNN-RNN」との間に有意差があった。これは株価の予測値が完璧な予測値には程遠く、誤差の大きい予測値であるためだと思われる。予測精度をさらに向上させることができれば、提案手法でさらに利益を上げることが可能である。



	今日の 実測値	Random	完璧- 完璧	完璧- RNN	RNN- RNN
今日の 実測値			○	○	○
Random			○	○	○
完璧-完璧				○	○
完璧-RNN					
RNN-RNN					

図 3. data1 の実験結果



	今日の 実測値	Random	完璧- 完璧	完璧- RNN	RNN- RNN
今日の 実測値			○	○	
Random			○		
完璧-完璧				○	○
完璧-RNN					
RNN-RNN					

図 4. data8 の実験結果




図 5. 利益の獲得状況




図 6. 学習データのヒストグラム




図 7. テストデータのヒストグラム




図 8. 利益の獲得状況

## 6. 今後の課題

RNN の予測値と Persistence Model の平均絶対誤差を比べると RNN の予測値のほうが良い結果を出すことができた。しかし persistence model と同様に後追いをしている。後追いを改善するにはニュースや新聞記事などのテ

クニカル指標だけでは判断できない指標を加えて予測する必要がある。

Q 学習では Q-table へ入力するとき値を量子化する必要がある。そのため連続値を取り扱うことができない。本来株価は連続値であるため学習機への入力値は連続値であることが望ましい。これを改善するにはニューラルネットワークを Q 学習に応用した Deep Q-Network(DQN)を用いればよい。Deep Q-Network はニューラルネットワークと同様に連続値を入力とすることができる。

実験の結果から株価の予測値を用いることで他の手法よりも利益を上げることができた。このことから Random に株売買をするよりも明日の予測値を用いたほうが、利益を上げることができるといえる。しかし完璧な予測値であればさらに利益を上げることができる。株価の予測精度を向上させることでさらに多くの利益を上げられるといえる。

## 謝辞

本研究を進めるにあたり、ご指導いただいた修士論文指導教員の平原誠准教授に心より感謝いたします。

## 参考文献

- 1) Jie Wangn, Jun Wangn, “Forecasting stock market indexes using principle component analysis and stochastic time effective neural networks”, Neural Networks, Vol.91, pp.8-20, 2017.
- 2) 松井藤五郎, 大和田勇人, “株式取引エージェントの強化学習への応用”, 2005 年度人工知能学会全国大会 (第 19 回) 論文集, pp. 1D4-01, 2005.
- 3) 造酒 裕貴, 狩野 悌久, 長尾 智晴 “深層強化学習を利用した株式売買戦略の構築” 電気学会研究会資料, ST 2018, pp.69-74, 2018.

## 学会発表

- [a] 渡邊祐太郎, 平原誠: 株価予測におけるニューラルネットワークと Support Vector Regression の性能比較, 2018 年電子情報通信学会ソサエティ大会, 2018.
- [b] 渡邊祐太郎, 平原誠: 強化学習を用いた株売買戦略の獲得, 2019 年電子情報通信学会総合大会, 2019.
- [c] 渡邊祐太郎, 平原誠: 株価の予測値を用いた株売買戦略の獲得, 第 76 回知的システム研究会, 2019