

# 深層学習を用いた株価予測の分析

## Stock Prediction Analysis using Deep Learning Technique

宮崎 邦洋<sup>\*1</sup>  
Kunihiro Miyazaki

松尾 豊<sup>\*2</sup>  
Yutaka Matsuo

<sup>\*1</sup> 東京大学工学系研究科技術経営戦略学専攻

Deep Learning techniques are rapidly being developed in many fields including stock price prediction. Convolution Neural Network is the most developing technique among them but has not been applied to financial field enough. In this study, we examine the possibility of usage of Deep learning technique, especially CNN, to financial time series data.

### 1. はじめに

近年、深層学習の発展が目覚ましい。論文投稿サイトの arXiv (<https://arxiv.org/>) では毎日のように深層学習の新しい論文が投稿され、その技術が発達している。

特に、近年のディープラーニングの発展の中心は画像処理や動画処理の分野で起こっており、それを支えている技術の一つが Convolutional Neural Network (CNN) の技術である。CNN では、入力データ(画像)に対して局所的な特徴抽出を担う畳み込み層と、局所ごとに特徴をまとめあげるプーリング層を用いることで(図 1)、画像の特徴を上手く捉えることができると報告されている[中山 2015]。

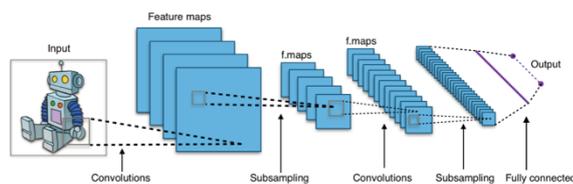


図 1. CNN の一般的な概念図<sup>1</sup>

深層学習の技術は株価予測にも応用可能である。まず、深層学習は一般的な時系列データの学習において発展を見せている。従来の時系列解析といえば、AR モデルや ARIMA モデルなど、過去何ステップかの時系列データを入力として、未来の時系列データを予測する線形モデルであった。一方、昨今のニューラルネットワークにおいては、系列データを利用できる Recurrent Neural Networks (RNN) やその発展系の Long short-term memory (LSTM) を使った手法が盛んに用いられている。RNN 自体は古くから使われている手法であり、LSTM ですら最初に発表されたのが 1997 年のことであるが、他のニューラルネットワーク同様、昨今のマシンパワーの向上と学習データの増大により、実用に耐えられるようになってきた。これらの手法により、特に自然言語処理や音声認識の分野において、系列データの学習は目覚ましい成果が見られている。

しかし、同じ時系列データでも、株価データは予測対象として難しい部類に入る。株価予測が困難である理由として、株価などの金融時系列データはほとんどランダムウォークの動きになることがあげられる。

同じマーケットにおいて多くのプレイヤーが取引に参加し、これらのプレイヤーが市場に出ている同じ情報に基づいて取引を

すると、プレイヤーは他プレイヤーとの情報格差を用いた裁定取引による利鞘を稼ぐことができなくなり、市場は効率的になる。効率的な市場では価格には公開情報はすぐに価格に織り込まれてしまい、価格変化を予測することは難しい。それにより、株価はランダムウォークの動きをすることになる[Basu 1977]。

しかし実際は、株価は完全なランダムな動きをするというわけではない。効率的市場仮説が科学的に正しいかどうかには議論があり [Lo 1988]、また実際に株価の値動きを観察していても、突然の乱高下や跳ね上がる株価が見られるなど、効率的とは言えない値動きが多く見られる。そのため、株価は完全な効率性を持っているわけではなく、過去のデータを入力とすることで予測力が向上する可能性はあると思われる。実際、機械学習の株価予測における適用においても、アルゴリズムを改善したことで予測力が改善したケースが見られており、一定の成果が見られている[Google 2015] [Wanjawa 2014]。そのため、より良いアルゴリズムを作成していけば、予測力の改善は見られるはずである。

本研究では、金融時系列に対しての CNN の応用可能性を検証する。CNN は前述したとおり、非常に高い特徴発見能力を有しており、時系列データにおいても株価変動のシグナルとなるような時系列パターンの発見ができることが期待される。

一般的な時系列データに対しての CNN の応用は既に行われており、音声認識や自然言語処理の分野において成果が見られている。しかし、筆者の知る限り、金融データにおける CNN の応用は多くなされていない。

また、CNN が株価予測に適していると思われるもう 1 つの理由として、市場に参加している人々の多くがテクニカル指標を用いて取引をしていることがある。株取引の世界ではテクニカル手法という、株価のチャート上の過去パターンに基づいて取引を行う手法がよく用いられている(図 2)。テクニカル指標を用いた手法こそ、まさに人間が目で見えてパターンを認識して行う手法となっている。テクニカル手法は、必ず儲けられる手法であるかは不明瞭な点があるが、テレビの市場解説のニュースでも用いられる程一般的な手法となっており、そこにはある種の定石のような取引パターンがあると思われる。また、それは特に財務情報を参照しにくい短期のトレードによって現れる可能性が比較的高いと考えられる。また、日中間のような短期の売買が主にテクニカル手法によって行われているのであれば、単純に人間と機械のパターン認識の勝負となり、この点においても、良い特徴発見能力を持つ CNN が勝てる可能性はあると思われる。

連絡先: 宮崎 邦洋, [miyazaki@weblab.t.u-tokyo.ac.jp](mailto:miyazaki@weblab.t.u-tokyo.ac.jp)  
松尾 豊, [matsuo@weblab.t.u-tokyo.ac.jp](mailto:matsuo@weblab.t.u-tokyo.ac.jp)

1 : By Aphex34 (Own work) [CC BY-SA 4.0 (<http://creativecommons.org/licenses/by-sa/4.0/>)], via Wikimedia Commons



図 2. テクニカル分析の例(トレンド分析)<sup>2</sup>

本研究では, CNN の特徴認識能力, そしてテクニカル分析の普及から, CNN を用いた株価予測が従来の手法に比べ予測力の改善が見られるかを検証する.

## 2. 関連研究

株価予測において機械学習の技術は多く行われている. 実際の手法ではインターネット上のセンチメントや企業の財務情報を入れて予測することが一般的であるが[Bollen 2011], 本実験では株価の値動きにおけるモデルの精度を確かめるため, 株価のみを用いて予測を行う.

CNN を時系列データに用いる手法は実際にある. 音声認識の分野など. 時系列データの特徴を捉える上でも CNN は有効であることが示されている[Yin 2017].

[Siripurapu]では, 株価の値動きを画像データに落とし込み, それを CNN の入力データとして扱う手法と提案している. 単一の銘柄の値動きだけでは画像データに対して情報も少なく効果は見られていないが, 株価の時系列データを CNN 適用する手法の多様性を示した. このように, 前処理として画像データの作り方を工夫する余地は多いにあると思われる.

## 3. 実験の枠組みと使用したデータ

### 3.1 株価データと実験

本研究では, 日経平均の値を, 日経平均自身の過去データと日経平均の主要構成銘柄 Topix Core 30 を入力データとして用い, 予測する. 予測の問題は日経平均株価の騰落の 2 値を予測する分類問題とした.

株価データの時間間隔は 30 分足のデータを用いた. 100 ステップ分のウィンドウを入力とし, ウィンドウから 1 ステップ先(30 分先)の価格の騰落を予測する. この場合, window は日をまたぐことになるが, その際, 9:00 のデータはブレが大きく, 除くことにした. また前ステップから間の空く 9:30 と, 昼休み後の 12:30 のデータには, 期間分の平方根で割ることで補正した.

予測する期間は 2016 年 1 月~6 月の 6 ヶ月間を 1 ヶ月ごとテストデータとして予測した. 学習データは予測する月から 1 年間遡ったデータを用いた. 最終的な精度評価は, 6 回の予測の平均を用いた.

### 3.2 比較手法

実験としては, 以下のモデルを作成し, それぞれの精度を確かめた.

- Rand-1: 学習データ 1 年間における日経平均の騰落率でテストデータの騰落を予測
- Rand-2: 1/2 の確率で騰落を予測
- LogisticRegression: ロジスティック回帰
- RandomForest: ランダムフォレスト
- MLP: 多層パーセプトロン(Dense4 層)

- LSTM: LSTM2 層+Dense2 層
- CNN: (Conv+Maxpooling)2 層+Dense2 層
- PCA-CNN: 前処理 PCA+ (Conv+Maxpooling)2 層+Dense2 層
- CNN-LSTM: (Conv1D+Maxpooling1D)1 層+LSTM2 層+Dense1 層

ニューラルネットワークは 4 層に統一した. それぞれ活性化関数は ReLU を使っており, 0.2 の割合で各層で Dropout を組み込んだ. 学習回数は 100 epoch とした.

## 3.3 CNN の株価予測への適用方法

株価を CNN への入力データとして使う方法として, 次の 2 つを試みた.

一つは, 入力データ(31 銘柄×100 ステップ)をそのまま画像と同様にして扱う手法. もう一つは, 銘柄の数と同数の主成分(第 1~第 31 主成分)を入力データとして用いる手法(PCA-CNN)である.

主成分を用いる理由は, そもそも CNN において畳み込みが行われる範囲では隣り合うピクセルに重要な意味があり, 隣り合う銘柄の順番の恣意性を除くためである.

これらのデータを CNN の入力とすることで, 複数銘柄の window 内での値動き(若しくは複数主成分の window 内値動き)を「画像」として認識し, 単一銘柄内のパターンだけでなく, 銘柄間や主成分間のパターンを抽出することが期待される.

## 4. 結果

結果は以下の通りである(表 1). 2 値分類問題であるため, Accuracy, F-score を指標においた.

表 1. 各手法における予測結果

モデル	Accuracy	F-score
Rand-1	0.512	0.504
Rand-2	0.511	0.491
LogisticRegression	0.496	0.488
RandomForest	0.555	0.500
MLP	0.528	0.514
LSTM	0.674	0.519
CNN	0.491	0.498
PCA-CNN	0.525	0.511
CNN-LSTM	0.525	0.508

まず注目すべきこととして, Accuracy は LSTM が群を抜いて高かった. しかし, 実際の予測結果は, 正例か負例のどちらかのみを予測結果として出力していた. そのため有効な予測結果とは言えないが, とはいえ一定以上の Accuracy があることを考えると, 長期的なトレンドの予測ができていく可能性がある.

その他のニューラルネットに注目すると, MLP, PCA-CNN, CNN-LSTM ではランダムな予測よりも Accuracy, F-score が共に改善している. これらの予測力が改善していることから, ランダムな予測よりも多層ニューラルネットによって予測力が改善した可能性が考えられる.

単純な CNN は予測力の低下が見られるが, 一方で PCA-CNN で予測力が改善していることから, ランダムに銘柄を並べるよりも, 恣意性の低い主成分を入力として並べた方が, 時系列データにおける CNN 利用としては適している可能性がある.

---

## 5. 考察と展望

今回は複数の手法でランダムな予測よりも予測力の改善が見られた。しかし、株価予測においては1%の予測力改善だけでも意味があるにせよ、よりロバストな検証結果のためには、より広い期間での検証が望まれる。

また、今回は比較のためもあり、比較的層が浅くシンプルなニューラルネットワークを用いたが、昨今の深層学習の研究ではより深く、課題に適した複雑なニューラルネットワークを用いる手法も多く開発されているので、ニューラルネットワークの構造を今後発展させていくことは重要であると思われる。

今回は単純に複数銘柄の時系列データを CNN に対して当てはめたが、他にも[Siripurapu]のように画像を実際に生成してデータとして用いる方法や、CNN のチャンネル(画像処理では色をデータとして使用する際に使う)を用いたモデルの工夫をしていくことで、その特徴抽出能力をさらに使用する方法はまだあると思われる。

## 6. まとめ

深層学習の主要なモデルの一つである CNN を株価予測に応用した。その結果、一定の予測力改善が見られ、金融データに対する CNN 利用の可能性を示した。

### 謝辞

本研究は JSPS 科研費 JP25700032,JP15H05327,JP16H06562 の助成を受けたものです。

### 参考文献

- [Bollen 2011] Johan Bollen, Huina Mao, Xiaojun Zeng : Twitter mood predicts the stock market, Journal of computational science, 2011.
- [Google 2015] Google: Machine Learning with Financial Time Series Data on Google Cloud Platform, 2015.
- [Jozefowicz 2015] Rafal Jozefowicz, Wojciech Zaremba, Ilya Sutskever: An empirical exploration of recurrent network architectures, Journal of Machine Learning Research, 2015.
- [Lo 1988] Lo, Andrew W., A. Craig MacKinlay: Stock market prices do not follow random walks: Evidence from a simple specification test, Review of financial studies 1.1 ,1988.
- [Maknickienė 2011] Nijolė Maknickienė, Aleksandras Vytautas Rutkauskas, Algirdas Maknickas: Investigation of financial market prediction by recurrent neural network, Innovative Infotechnologies for Science, Business and Education, 2011.
- [中山 2015] 中山英樹, 深層畳み込みニューラルネットワークによる画像特徴抽出と転移学習, 信学技報 115.146, 2015.
- [Basu 1977] Sanjoy Basu: Investment performance of common stocks in relation to their price-earnings ratios: A test of the efficient market hypothesis, The journal of Finance 32.3 , 1977
- [Siripurapu] Ashwin Siripurapu: Convolutional Networks for Stock Trading.
- [Wanjawa 2014] Wanjawa Barack Wamkaya, Muchemi Lawrence: ANN Model to Predict Stock Prices at Stock Exchange Markets, 2014.
- [Yin 2017] Wenpeng Yin, Katharina Kann, Mo Yu, Hinrich Schütze: Comparative Study of CNN and RNN for Natural Language Processing, arXiv, 2017.