

The Prediction of the Fluctuation of Stock Index by Using Convolutional Neural Network

Kenji SHIRAKATA*, Hiroshi TSUDA*

(Received April 20, 2018)

Today, the use of the deep learning is being focused with the development of the information technology. Recently it is shown that using deep learning for several data is effective, especially pictures or text. Therefore, many researchers have been using deep learning to analyze or predict the financial market. In addition, the spread of Internet enable people to get stocks in lower brokerage. Then the number of the private investors is increasing nowadays. By the way, there are two ways to analyze stock price. They are the fundamental analysis and the technical analysis. The technical analysts use the patterns of stock price change to know whether they invest or not. And not a few people make profits by technical analysis. But this method depends on personal skills so that it is subjective.

Thus, we tried to predict the fluctuation of stock price by Convolutional Neural Network (CNN). Then the goal of our research is to develop the method of the prediction about the fluctuation of stock price by CNN.

Key words: deep learning, Convolutional Neural Network (CNN), stock price prediction, technical analysis

キーワード: 深層学習, 畳み込みニューラルネットワーク (CNN), 株価予測, テクニカル分析

畳み込みニューラルネットワークによる株価インデックス騰落予測

白方 健司, 津田 博史

1. はじめに

近年, 情報技術の発展に伴い, 深層学習の活用が注目されている. 最近では, 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¹⁾. そのため, 金融市場の分析や予測において, 深層学習を応用する動きが活発になっている. また, 近年, インターネットの普及により株式取引の手数料の低コスト化が実現されるとともに, 個人投資家の数が激増している. ところで, 株式予測には大きく分けてファンダメンタル分析とテクニカル分析の 2 つが存在する. その中で, テクニカル分析により収益を上げている個人投資家も少なくない. テクニカル

分析では, 株価チャート(株価をグラフ化したもの)のパターンなどから相場の方向性(将来の株価騰落)や売買タイミングなどを予測する^{2,3)}. しかし, テクニカル分析には主観的な投資判断となる側面もある.

そこで, 本研究では, 株価チャートを画像化したデータに対して深層学習を用いることで, 株価騰落予測モデル構築を行う. そして, 予測精度の高いモデルの構築と従来の主観的な投資判断に客観性を見出すことを目的とする.

*Department of Mathematical Sciences, Doshisha University, Kyoto
Telephone: +81-774-65-7443, E-mail: htsuda@mail.doshisha.ac.

2. 使用データ

株式会社 Quick の Astra Manager から取得可能な 1980 年 1 月から 2017 年 12 月までの株価データを使用した。分析対象は、主に日経平均株価とし、東証業種別インデックス (33 種) についても検証を行った。

3. 分析手法

3.1 分析環境

Python3 を使用した。ディープラーニングを実装するためのフレームワークとして Keras を使用し、バックエンドには Tensorflow を使用した。また、モジュールとしてチャート画像を作成するために mpl_finance, matplotlib を使用し、時系列クラスタリングのために tslearn を使用した。

3.2 モデルについて

モデルは、Keras で利用可能な VGG16 と ResNet50 を Fine-tuning して使用する。本研究では、騰落予測 (2 クラス分類) のため、全結合層を 2 ユニットとし、初期の重みには ImageNet を使用した。また、損失関数には、binary_crossentropy を使用し、最適化には確率的勾配降下法を使用した。予測期間は、2013 年から 2017 年の 5 年間とし、各年初にモデルを更新する。

3.3 予測モデルの構築

3.3.1 ラベル付け

ラベル付けは、予測期間に応じて現時点と予測時点を比較し行う。予測期間が p 、 t 時点における株価を P_t としたとき、訓練データのラベル L_t を以下で定義する。

$$L_t = \begin{cases} 0 \text{ (down)} & \text{if } R_t < 0 \\ 1 \text{ (up)} & \text{else} \end{cases}, \quad R_t = \frac{P_{t+p}}{P_t}$$

3.3.2 学習データとテストデータ

予測年の 1 年間分のデータをテストデータとして、予測年より前のデータ全てを学習データとする。例えば、2015 年の株価予測モデルは、2014 年 12 月末までのデータを学習データとしモデルを構築し、

2015 年 1 月初から 2015 年 12 月末までをテストデータとする。そのため、各年におけるモデルの学習データ量は異なり、2017 年のモデルの学習データ量が一番多いものとなっている。また、学習データの 8 割をトレーニングデータ、残り 2 割をバリデーションデータとした。

3.3.3 予測モデルの構築と評価方法

トレーニングデータにより重みを更新し、モデルを構築する。その際に、エポック数は 30 とした。そして、各エポックにおいて更新された重みについてバリデーションデータにより評価し、バリデーションデータ全体に対する誤差 (val_loss) が最小な重みを最適な重み¹⁾とし、予測モデルとして使用する。また、本研究ではホールドアウト検証を 2 回行っている。そのため、各年の予測モデルは 2 つあり、予測結果は 2 つのモデルの平均とした。

次に作成された予測モデルにテストデータを入力し、予測を行う。そして、予測結果の的中率を算出し、予測モデルの評価を行う。

4. 分析結果および考察

4.1 日経平均株価騰落予測

日経平均株価について、チャート画像のウィンドウサイズを 75 としローソク足のみのチャート画像 (Fig. 1) を分析データとした。そして、スイングトレードを想定し、予測期間を 15 日後とし、VGG16 と ResNet50 により予測モデルをそれぞれ構築した。また、両モデルの予測の平均をとった VGG16 と ResNet50 の合成予測モデル (VGG16+ResNet50) を作成した。各モデルの過去 5 年間の予測結果は、以下の Table 1 に示す。



Fig. 1. Daily Chart of 75 Days.

Table 1. Accuracies of predictions for Nikkei Stock Average.

Index	test year	VGG16	ResNet50	VGG16+ResNet50
Nikkei Stock Average	2013	53.9%	59.6%	61.2%
	2014	61.9%	58.6%	64.8%
	2015	52.1%	44.3%	48.0%
	2016	55.1%	56.3%	53.5%
	2017	62.4%	65.6%	64.0%
	Average	57.1%	56.9%	58.3%

まず, VGG16 と ResNet50 によるモデルでは, VGG16 によるモデルの方が全体としての的中率が高い. また, ResNet50 によるモデルは 2015 年においては 50% を下回っている. したがって, VGG16 によるモデルの方が ResNet50 によるモデルより良いと言える. また, VGG16 と ResNet の合成予測モデルは, 全体としての的中率は向上しているが, 2015 年において 50% を下回っているため良いモデルとは言えない. しかし, 2013 年と 2014 年について着目すると, 合成前に比べてパフォーマンスが向上しており, 興味深い結果となっている. 2015 年の ResNet50 によるモデルの低い精度のため, 合成予測モデルの性能は低下してしまう結果となったが, 複数のモデルを合成することは価値のあることのように思われる. 一般に, ResNet50 は画像認識では VGG16 より高い性能であると言われている¹⁾が, 今回の入力画像はローソク足だけのシンプルなものであり, 特徴量が少ないため VGG16 によるモデルとの精度に大差がつかなかったのかもしれない. 本研究では, 学習時間やモデルの性能に大差がないことを踏まえ, 以降は VGG16 によるモデルを中心に精度向上を図っていく.

4.2 日経平均株価騰落予測モデルの精度向上

VGG16 によるモデルの的中率の内訳を Table 2 に載せた. まず, 全体として 2013 年と 2015 年の的中率が低いことがわかる. 特に, 2013 年の down の的中率が低い. そこで, この 2 年について, 的中率が低下した原因を考察する.

4.2.1 精度が低い原因

まず, 2013 年において 5 月から 6 月と 7 月から 8

Table 2. Details about prediction results of the model made by VGG16.

“accuracy” is prediction accuracy of each year,
“down” and “up” are prediction accuracies when the model predicts each labels,
“up:down” is the ratio of each labels to a year.

Index	test year	accuracy	down	up	up:down
Nikkei Stock Average	2013	53.9%	17.0%	64.1%	0.68:0.32
	2014	61.9%	55.6%	69.4%	0.56:0.44
	2015	52.1%	37.2%	60.1%	0.61:0.39
	2016	55.1%	43.0%	66.9%	0.62:0.38
	2017	62.4%	50.0%	78.0%	0.62:0.38

月の 2 期間が特に予測精度が悪かった. 2013 年 5 月から 6 月において精度が低い原因として, 2013 年 5 月 23 日の大暴落が考えられる. 当時, 中国の景気指標悪化などを理由に売りが膨らみ, 戦後の下落率 10 位を記録するほどの大暴落となった. そのため, パターン認識だけでは考慮できない要因により精度が低下してしまったものと思われる. したがって, 当モデルはファンダメンタルズの影響に弱い可能性がある. そのため, モデルの精度向上にはファンダメンタルズを考慮する必要がある. あるいは, 当時の相場は右肩上がりでも急上昇していたため, 過熱気味だった. そこで, 相場の加熱度合いを考慮できるような特徴を画像に追加したり, 加熱度合いに関する指標を併せたりすることでモデルの精度向上が期待できると思われる. 次に, 2013 年 7 月から 8 月のチャート画像 (Fig. 2, Fig. 3) は, ウィンドウサイズの大きさ次第で見え方が変わる. Fig. 2 だけで見ると, 相場に方向感のない横ばいの相場³⁾に見える一方で, Fig. 3 だけで見るとテクニカル分析のフォーメーション分析におけるダブルトップの形状³⁾をしているように見える. 一般に, ダブルトップが現れると将来的には相場は下降する³⁾と言われている. 実際に, 2013 年 7 月から 2013 年 8 月のラベルは, down がほとんどを占めていた. そこで複数のウィンドウサイズを考慮することで, モデルの精度向上が期待される. また実際にトレードをする際は, 大域的な見方から局所的な見方をする人が多い²⁾.

次に、2015 年において、全体的に 1 月から 2 月と 11 月から 12 月末の 2 期間で予測精度が低くなっている。2015 年 1 月から 2 月末のチャート画像 (Fig. 4) を見てみると、テクニカル分析で三角保ち合いと言われている予測しづらい相場³⁾になっている。そこで、予測しやすい相場と予測しづらい相場を分けてモデルを構築し予測することで精度向上が期待できると思われる。また、2015 年 11 月から 2015 年末のチャート画像 (Fig. 5, Fig. 6) を見てみると、ウィンドウサイズの違いにより見え方が異なる。Fig. 5 を見てみると、フォーメーション分析におけるトリプルボトムの形状からトレンドの転換により上昇と判断するのが一般的である³⁾。一方で、Fig. 6 を見てみると、フォーメーション分析におけるダブルトップからトレンドの転換により下降と判断するほうが妥当である³⁾。このように、一つのウィンドウサイズだけでは予測できないため、複数のウィンドウサイズを考慮すべきだと思われる。実際、この画像の正解ラベルは down であり、ウィンドウサイズが 150 によるモデルでは的中していた。したがって、Fig. 2, Fig. 3 の例と同様に複数のウィンドウサイズを考慮することが必要だと思われる。




Fig. 2. Daily chart of 75 days in 2013/7/29.




Fig. 3. Daily chart of 150 days in 2013/7/29.




Fig. 4. Daily chart of 75 days in 2015/2/24.




Fig. 5. Daily chart of 75days in 2015/12/16.




Fig. 6. Daily chart of 150days in 2015/12/16.

4.2.2 複数のウィンドウによるモデルの作成

ウィンドウサイズを 150 日 (6 ヶ月) と 225 日 (9 ヶ月) として、15 日後の株価騰落予測モデルをそれぞれ作成した。結果を Table 3 にまとめた。全体として、ウィンドウサイズを大きくすることでの的中率は低下している。その要因の一つとして、畳み込みニューラルネットワークの特性上、ウィンドウサイズが大きいチャート画像では、多くの情報が特徴マップに集約されてしまうためだと思われる。しかし、4.2.1 で述べた期間における的中精度は向上した。例えば、2013 年 7 月 1 日から 8 月 9 日の予測精度は、ウィンドウサイズが 75 のとき予測精度は 10.3%

だった。しかし、ウィンドウサイズを 150 にしたモデルでは 37.9%、ウィンドウサイズを 225 にしたモデルでは、75.9%と大幅に向上した。したがって、ウィンドウサイズを変更することは、一概に悪いとは言えない。相場によって適したウィンドウサイズを適用できれば、精度の向上につながるのではないと思われる。また、複数のウィンドウサイズにより作成されたモデルを組み合わせることで、パフォーマンスの向上が期待できると考えた。なぜなら、局所的な相場の見方から大域的な相場の見方までを判断したモデルになるからだ。その結果を Table 4 にまとめた。Table 4 を見てみると、全体としての精度は向上していない。しかし、年によっては精度が向上している。例えば、2014 年では複数のウィンドウを組み合わせの方が元のモデルの精度 (61.9%) より精度が向上しているものもある。したがって、複数のウィンドウサイズを考慮するはモデルの精度向上につながる可能性がある。

4.2.3 予測しづらい相場の除外

横ばいの相場は、テクニカル分析では予測しづらいと言われている³⁾。そこで、時系列クラスタリングにより横ばいの相場の抽出を試みた。時系列クラスタリングには、Python の tslearn をモジュールとして使用し、k-means 法 (DTW) とした。テクニカル分析では、RSI が 50% (0.5) ラインを上下しているときは、横ばいの相場が多い³⁾という見解がある。そこで、RSI の過去 25 日間の時系列をクラスタリングし、50% ラインを上下しているクラスターを除外することで、モデルの精度を向上につながると考えた。ここで、RSI は以下の式³⁾で求めた。

$$RSI = \frac{A}{A+B} \times 100(\%)$$

A: N 日間の値上がり幅の合計

B: N 日間の値下がり幅の合計

予測モデルの構築と検証は、以下の手順で行った。

- ① 各時点において過去 25 日間の RSI を求める。
- ② ①で求めた RSI について、トレーニングデータの期間内でクラスタリングを行い、クラスタリ

Table 3. Accuracies of predictions by several window size models in each year and average the accuracies.

test year	75	150	225
2013	53.9%	60.8%	71.0%
2014	61.9%	57.4%	52.1%
2015	52.1%	51.2%	42.6%
2016	55.1%	58.4%	44.5%
2017	62.4%	49.4%	50.6%
Average	57.1%	55.4%	52.2%

Table 4. Accuracies of predictions by combined several window size models in each year and average accuracies.

test year	75	75+150	75+225
2013	53.9%	61.6%	60.4%
2014	61.9%	63.1%	59.4%
2015	52.1%	49.6%	48.8%
2016	55.1%	56.3%	50.6%
2017	62.4%	50.2%	53.8%
Average	57.1%	56.2%	54.6%

test year	150+225	75+150+225
2013	69.8%	68.2%
2014	54.1%	62.3%
2015	49.6%	45.1%
2016	49.8%	53.9%
2017	44.5%	49.8%
Average	53.6%	55.8%

ングを行い、クラスタリングモデルを構築する。同時に、トレーニングデータの各クラスターのセンターデータを図示する。

- ③ ②で図示されたセンターデータを比較し、50% ラインを上下しているクラスターを除外クラスターとする。
- ④ トレーニングデータについて、除外クラスター以外のデータから予測モデルを構築する。
- ⑤ テストデータについて、②で作成されたクラスタリングモデルによりクラスター番号を振り分ける。
- ⑥ ⑤のデータについて、除外クラスター以外を④で作成された予測モデルにより予測を行う。

まず、クラスター数を3として予測モデルを構築した。クラスター数を3にした理由は、一般に『上昇(Buy)、横ばい(Hold)、下降(Sell)』の3通りの基準があるためである。このモデルによる結果がTable 5である。Table 5より、2015年の精度は向上したことがわかる。しかし、全体として予測精度は大幅に低下している。その原因は、除外クラスターに的中しやすいものが多く含まれていたことや学習データ量の減少によりモデルの悪化が考えられる。そこで、各クラスターの特徴を明確にするためにクラスター数を5とした。5とした理由は、『強い上昇(Strong Buy)、上昇(Buy)、横ばい(Hold)、下落(Sell)、強い下落(Strong Sell)』という5通りの基準があるためである。このモデルによる結果がTable 6である。Table 6を見ると、全体として予測精度は向上している。一方で、2016年のパフォーマンスの低下が気になる。その要因を特定するために、各年のモデルの予測結果の変化をTable 7に示す。Table 7より、2016年だけがクラスタリングによるモデルは性能が低下してしまったことがわかる。つまり、2016年においては、除外クラスターに該当するデータの欠落により、トレーニングデータの質が低下したと考えられる。そのため、クラスタリングがうまく機能しなかったと思われる。したがって、クラスタリングをうまく機能させるために、クラスター数を変更したりクラスタリング手法を変えたりなど改善の余地があると考えられる。

ここで、各年のクラスターの内訳Table 8に示した。ここで注目してほしいのは、2015年以外はクラスター0の的中率が高いが、それを除外したにもかかわらずモデルの精度が向上していることである。このことから、クラスタリングを行うことで、予測しにくい相場を除外するだけでなく、全体として学習データが改善されたことが読み取れる。したがって、クラスタリングにより相場を限定することはモデルの予測精度改善に価値のあることだと思われる。

Table 5. Accuracies of model predictions after deleting cluster (cluster number=3).

“before” is conventional model, “after” is the model that excepted a delete cluster, “del_cluster” is cluster number which have to be deleted.

test year	before	del_cluster	after
2013	53.9%	0	49.6%
2014	61.9%	0	54.4%
2015	52.1%	0	59.7%
2016	55.1%	0	52.9%
2017	62.4%	0	39.9%
Average	57.1%		51.3%

Table 6. Accuracies of model predictions after deleting cluster (cluster number=5).

test year	before	del_cluster	after
2013	53.9%	0	56.5%
2014	61.9%	0	68.3%
2015	52.1%	0	63.3%
2016	55.1%	0	43.6%
2017	62.4%	0	64.7%
Average	57.1%		59.3%

Table 7. The improvement number of the prediction by the model which excepted a delete cluster in each year.

test year	improve	worse	improvement number
2013	29	23	6
2014	40	25	15
2015	27	19	8
2016	25	48	-23
2017	29	19	10

Table 8. Accuracies of the predictions at each cluster in test year.

test year	accuracy of each cluster				
	cluster 0	cluster 1	cluster 2	cluster 3	cluster 4
2013	55.8%	30.0%	64.3%	61.8%	45.5%
2014	67.2%	40.0%	56.4%	71.0%	65.8%
2015	34.3%	54.9%	75.0%	61.5%	52.5%
2016	55.8%	46.7%	44.4%	60.3%	71.4%
2017	70.3%	36.7%	78.0%	24.0%	79.3%

4.2.4 予測期間の変更

予測期間は、ハイパーパラメータなため最適な予測期間を見つけることは難しい。そこで、いくつか予測期間を変え、それぞれの的中率を求めた。その結果を Table 9 に示す。Table 9 より、予測期間の違いでモデルの予測精度に差が出ることがわかる。今回の研究では、20 営業日後の予測によるモデルが全体として一番良いものとなった。

Table 9. Accuracies of the models whose prediction spans are several.

test year	accuracy of each prediction span				
	10 days later	15 days later	20 days later	25 days later	30 days later
2013	57.6%	53.9%	63.7%	64.9%	49.8%
2014	51.6%	61.9%	61.5%	62.3%	61.5%
2015	48.8%	52.1%	53.7%	61.1%	42.6%
2016	64.9%	55.1%	51.8%	48.2%	49.4%
2017	52.6%	62.4%	64.2%	58.8%	58.4%
Average	55.1%	57.1%	59.0%	59.1%	52.3%

4.2.5 閾値により弱気の予測を除外

今回、作成したモデルは up と down の予測を出力するが、その際にそれぞれの確率値を算出し、値の大きいほうを出力するものとなっている。そのため、各時点において客観的な投資判断となる指標を得ることが出来る。また、閾値を定め弱気な予測を除外することで、精度の向上につながると思われる。そこで、閾値を指定して的中率を算出したものとして Table 10 に示す。また、RSI によりクラスタリングしたモデルの結果を Table 11 として示す。Table 10, Table 11 どちらも、閾値を上げることでモデルの精度が向上している。そのため、閾値を指定することはモデルの精度を向上させるために有効である。一方で、閾値を指定することで予測回数が減ってしまう。しかし、RSI により当てにくい相場を除外し、閾値を 0.9 にしたモデルは、高い精度を誇っていると思われる。

4.3 東証業種別インデックスにおける予測

最後に、東証業種別インデックスを対象にモデルを構築し、検証を行った。その結果を Table 7 に示す。また、上位 3 業種と下位 3 業種について抽出したものが Table 12 である。この結果から、モデル

Table 10. Accuracies of default model with threshold.

test year	before	threshold			
		0.6	0.7	0.8	0.9
2013	53.9%	55.1%	55.4%	56.3%	57.1%
2014	61.9%	66.7%	67.9%	68.7%	68.9%
2015	52.1%	52.6%	50.6%	44.4%	39.8%
2016	55.1%	52.8%	52.1%	51.9%	61.0%
2017	62.4%	63.5%	64.3%	66.7%	70.8%
Average	57.1%	58.1%	58.0%	57.6%	59.5%

Table 11. Accuracies of the model screened by RSI with threshold.

test year	before	threshold			
		0.6	0.7	0.8	0.9
2013	56.5%	58.6%	60.2%	64.2%	79.3%
2014	68.3%	66.9%	68.8%	74.1%	74.0%
2015	63.3%	67.4%	68.3%	65.3%	55.6%
2016	43.6%	46.8%	47.3%	42.9%	46.9%
2017	64.7%	64.7%	65.9%	68.2%	76.0%
Average	59.3%	60.9%	62.1%	62.9%	66.4%

作成の対象により精度のばらつきが伺える。つまり、本研究におけるモデルは対象によって適用するときとしないときがあることがわかる。そのため、対象を決める基準などを考慮していくことが今後の課題だと思われる。

5. まとめ

今回、株価の 4 本足(始値、高値、安値、終値)をローソク足としてチャート画像化し、畳み込みニューラルネットワーク(CNN)に適用することで、騰落予測が可能であり、各時点における騰落予測に確率値を算出することが出来、チャートパターンを定量的に評価することが出来るようになった。また、予測しづらい相場をクラスタリングにより除外したり、予測値の確率に閾値を設定したりすることでモデルの精度を向上させることが出来るという新たな知見が得られた。更に、相場に応じたウィンドウサイズにチャート画像を変更したり、複数のモデルを組み合わせたりすることでモデル精度向上の可能性を見出すことが出来た。今回の研究は、AI トレードや銘柄抽出、リスク管理など様々な分野への適用が期待出来ると思われる。




Fig7. Average prediction accuracies for the Nikkei Stock Average or TSE Industry in test year.

Table12. The top 3 and bottom 3 indexes of average accuracy in test year.

test year	Services	Chemicals	Nikkei Stock Average	test year	Other Products	Iron and Steel	Air Transportation
2013	56.7%	58.8%	53.9%	2013	56.7%	47.4%	49.0%
2014	54.1%	57.0%	61.9%	2014	40.6%	48.8%	44.7%
2015	57.4%	50.4%	52.1%	2015	36.1%	36.5%	43.9%
2016	56.3%	53.1%	55.1%	2016	52.2%	42.5%	42.5%
2017	73.7%	70.5%	62.4%	2017	51.8%	53.9%	42.5%
Average	59.6%	57.9%	57.1%	Average	47.5%	45.8%	44.5%

6. 今後の課題

モデルの対象によって精度にばらつきがあったので、対象を決める際の基準を明確にしていく必要がある。また、クラスタリングにより相場を限定することで全体としての精度を向上させることは出来たが、2016 年に関しては精度が低下してしまった。そのため、相場の限定手法の改善をしていく必要があると思われる。更に、除外クラスターを選ぶ際に客観性のある基準がないため改善していく必要がある。そして、ファンダメンタルズの影響を受けることもあったので、ローソク足だけのインプットでの予測には限界がある。そこで、新たに画像に

特徴量を加えたり、マクロ指標などを考慮したりすることでモデルの改善が期待できるのではないかなと思われる。

参考文献

- 1) 藤田一弥, 高原歩, 実装ディープラーニング, (オーム社, 東京, 2016), pp. 80-149.
- 2) 相場師朗, 株は技術だ!倍々で勝ち続ける究極のチャート授業, (ばる出版, 東京, 2016).
- 3) 福永博之, ど素人が読める株価チャートの本, (翔泳社, 東京, 2016).