

修士学位論文

ソーシャルメディアの投稿記事と
テクニカル指標を用いた
市場予想に関する研究

2022年度
広域科学専攻 広域システム科学系
31-216828
呉沛昊

第1章 はじめに	3
第2章 関連研究	2
2.1 市場予測の一般手法	2
2.2 機械学習を用いない市場予測	2
2.3 機械学習を用いる市場予測	2
2.4 感情分析	3
2.5 感情分析を用いた市場予測	3
第3章 Jing(2021)の研究とその再現	4
3.1 Jing(2021)の研究の概要	4
3.1.1 感情分析	4
3.1.2 テクニカル指標の計算	6
3.1.3 LSTMを用いた予想	6
3.1.4 結果	7
3.2 Jingらの論文の追試	8
3.2.1 scrapingによる株価データの取得	8
3.2.2 scrapingによる掲示板書き込みデータの取得	9
3.2.3 感情分析	10
3.2.4 LSTMを用いた予想	11
3.2.5 対照手法	12
3.2.6 実験	12
3.2.7 考察	15
第4章 提案手法	16
4.1 市場シミュレーションによる評価	16
4.2 Optunaを用いたハイパーパラメータ調整	16
4.3 ほかの株の話の除去	17
4.4 BERTを用いた感情分析	18
第5章 実験	19
5.1 市場シミュレーションによる評価	19
5.2 Optunaを用いたハイパーパラメータ調整	21
5.3 ほかの株の話の除去	23
5.4 BERTを用いた感情分析	24
第6章 考察	25
参考文献	26

第1章 はじめに

株式市場は教育、技術、ビジネスなどの領域、また経済に大きな影響を与えてきた。証券あるいは株式の開始以来、その動きを予測する需要があった。人々の生活水準が上がるにつれて、投資、特に株式投資の需要が高まった。株式投資が上手な人、及び専門投資家の意見の重要度が上がり、人々はその意見を仰いだ。近年、人間のエキスパートの代わりにコンピュータを用いて株式の動きを予測し、その収益を制御することで、株式投資家に利益をもたらすことを目的にした研究がおこなわれている。

伝統的な株価予測としては時系列モデルに基づいた手法が多く提案されている。一変量解析の範疇に入る統計的アプローチでは、自己回帰移動平均(ARMA)、自己回帰統合移動平均(ARIMA)、一般化自己回帰条件付き異種分散(GARCH)ボラティリティ、円滑推移型自己回帰(STAR)モデル等が用いられる。それらは特定の時系列モデルを仮定した上で回帰分析をおこなう。一変量解析はランダムウォーク的な状態における予測に関しては有効だと考えられるが、一般の株価予測に関しては不十分であると考えられている。

コンピュータによる株価予測を有効におこなうためには、他の情報、例えば、投資家の感情や経済情勢などを扱うことが有効と考えられる。投資家の感情や経済情勢など、数値化が難しく、多くが自然言語で提供されているデータについては、コンピュータで有効に扱うことが困難であるため、それらを用いた株価予想は十分研究されてこなかった。最近になって、コンピュータで自然言語を扱う技術が一般化されたこと、多くの投資家の発言などをSNS等で大量に集め処理することが可能になったため、それらをコンピュータで処理して株価予測に用いる研究がいくつか始めている。

株式は400年以上前から発展しており、中国の証券市場は1990年代初頭に初めて出現した。30年以上の発展を経て、中国の証券市場は徐々に改善され、ダイナミックな市場になっている。中国では、株式投資に携わる投資家が増加し、個人投資家の割合が大きくなっており、株式は多くの人々がリスクを負うことをいとわない財務管理手段となっている。同時に、株式市場の価格変動は、一般に国民経済の発展や株式発行企業の経営状況を反映している。したがって、株式市場の効果的な分析は、経済全体にとっても、投資家一般にとっても興味深い研究テーマである。中国の株式市場に関する研究では、投資家心理や経済状況を判断するために英語のテキスト(英字新聞のニュースなど)をソースとするものがあるが、中国語のテキストをソースとする研究の方がより多くの投資家の心理を反映させたものになると考えられる。

伝統的な株価予測では比較的少数のパラメータを持つ単純な時系列モデルが用いられるが、実際の株価を予測するには多数のパラメータからなる複雑なモデルを用いる必要があると考えられる。近年NN(ニューラルネットワーク)、特にDNN(ディープニューラルネットワーク)を用いた回帰手法が用いられることが多くなっている。株価予測は、時系列データを入力とすることが自然であり、時系列データを直接入力できるDNNとしてRNN(Recurrent Neural Network)が適用可能である。そのため、株価予測にDNNを用いる研究の多くでは、RNNの中でも、最近は勾配消失問題に悩まされにくいLSTM(Long Short-Time Memory)が多く使われている。

中国語のSNSを感情分析で解析して、中国株の予測に用いるという先行研究を探したが、多くは見つけることはできなかった。原因の一つは、株価予測のプログラムを作成して、役に立つも

のができても、研究として公開せずに運用して利益をあげているケースがあると考えられる¹。また、見つかった先行研究を何本か調べたが、最低限の実験、評価すらおこなっていないもの、実験の条件が明確になっていないもの、予測のために用いるデータが一般に入手できないもの、論文中で明らかな leakage があるものなど、質の低い論文が多かった。

そんな中で、(Jing, Wu, and Wang 2021)という近年のこの領域の論文の中でcitationがある程度あり、再現ができそうで、知っている会社の株を扱った論文を見つけることができた。そこで、まず (Jing, Wu, and Wang 2021)の追試をおこなった上で、改善を提案するかたちで研究を進めることにした。

追試の結果、Jingらの論文のモデルの性能の問題点が見つかった。まず、Jingらの論文で試みていない一番な予測方法「前日の終値をそのまま次の日の終値と予測する方法」が、MAPEによる評価では最も良い方法と見なされることがわかった。これに対応するため、予測値を単純な正解との誤差の大小で評価するのではなく、予測値を元にした市場取引のシミュレーション結果の収益で評価することを提案する。この結果、Jingらの論文で提案する手法での予測値を使った市場取引シミュレーションの結果の方が、「前日の終値をそのまま次の日の終値と予測する方法」に相当する1/2の確率でその日の売買を決定するよりも良い結果となることがわかった。

また、Jingらの論文でグリッドサーチの結果得られたハイパーパラメータについて、より進んだハイパーパラメータチューニング用のフレームワークである Optuna を用いてチューニングする方法を提案した。この結果、Jingらの論文で5層のLSTMを用いていたのに対して、1層のLSTMを用いると MAPE による評価でも、市場取引シミュレーションを用いた評価でも良い結果を得た。

また、(Jing, Wu, and Wang 2021)感情分析について二つの手法を提案した。一つ目は、ほかの株の名前が書いてある投稿を排除すること。二つ目は感情分析に精度の高いBERTベースの感情分析を用いることである。どちらも、単独で適用した範囲ではMAPEによる評価では改善はみられなかったものの、市場取引シミュレーションを用いた評価でも良い結果を得た。一方で、両方を組み合わせたものは、BERTベースの感情分析を適用しただけのものよりも若干劣る結果になった。

以下、第2章で金融予測と感情分析に関しての関連研究を述べ、第3章で(Jing, Wu, and Wang 2021)の研究の中の感情分析と株価予測とその再現と再現結果について展開し、第4章で感情分析の改善(他の株に関する話題除去とBERTの適用)にも触れ、第5章でそれぞれの改善案の実験結果を述べてから、第6章で考察とまとめになる。

¹ 実際に多くの証券会社では、株のプログラム売買は一般的であるし、そのための株価予測プログラムも作成されている可能性が高いが、その原理などが論文として公開されているものはほとんどない。

第2章 関連研究

2.1 市場予測の一般手法

市場の動的, 非線形, 非平滑, ノンパラメトリック, ノイズ, カオスの性質上, 株式市場の動きと価格行為を予測するのはかなり困難である(Abu-Mostafa and Atiya 1996). 株式の価格は様々な要素によって左右されている (Zhong and Enke 2017),. 株式予想に用いられる分析手法は主にテクニカル分析とファンダメンタル分析に分類される(Park and Irwin 2007); (Nguyen, Shirai, and Velcin 2015). 投資家たちは主にこの二つの方法で, ローリスクハイリターンへの投資をしようとしている(Arévalo et al. 2017).

有効市場仮説(EMH, Efficient Markets Hypothesis (Fama 1970))によると, 株式市場での価格変化は予測不可能であり, それを予測する努力は無意味である. しかし, 株式市場における非常に多くの価格動向の存在と, 市場に影響を与える基本的なイベントと経済数値の間の割引前の系列相関は, EMHに反する多くの証拠のうち2つであると主張する. 研究者と投資家の多くはどちらもEMHを認めず, 市場の参加者の行動と心理を中心とした議論に重点を置いている ((Naseer and Bin Tariq 2016)). 株式市場の大きな波動は投資家たちの感情によって起きることが多いと考えられている.

株式市場の予測については短期的な予想と長期的な予想がある. 短期的な予想の難易度が相対的に高く, 不確定性の影響が大きい. 短期予測は具体的に株価の数値的な予想をし, 確定的な数値を目標にする. 長期予測は株価の勢いと範囲の予想をし, 株価の分布を目標にする. 短期予測の中には時間単位, 秒単位での取引を想定した研究もあるが, この研究では短期予測の中でも比較的長めな1日後の株価を対象とする.

また, 市場予測には, S&Pなどの指数の予測と個々の銘柄の株価予測がある. 指数の予測については, マクロ経済の影響が強く, 国や地域の経済全体に関係する広い範囲の情報を扱う必要があると考えられる. 一方, 個々の銘柄の株価予測については, マクロ経済の影響はうけるものの, 所属業界と個々の企業の情報の重みが強いと考えられる.

2.2 機械学習を用いない市場予測

機械学習技術が登場する以前は, 一般的に線形性, 定常性, 正規性を仮定した統計的手法が株式の分析・予測手法として提供されていた. 株式分析の中の時系列は, 時間的序列によって収集された観測データである, 例えば株の毎日の価格と売上などが観測データとして用いられることが多い(Fu et al. 2005).

入力変数として時系列を使用するため, 一変量解析の範疇に入る統計的アプローチには, 自己回帰移動平均 (ARMA), 自己回帰統合移動平均 (ARIMA), 一般化自己回帰条件付き異種分散 (GARCH) ボラティリティ, 円滑推移型自己回帰 (STAR) モデル等が用いられている.

ARMAモデルは, 株式市場分析に広く用いられている手法である(M, Hiransha et al. 2018). ARMAは, 取引市場でしばしば観察されるモメンタム効果や平均回帰効果を説明しようとする自己回帰 (AR) モデルと, 時系列で観察されるショック効果を捉えようとする移動平均 (MA) モデル

とを組み合わせたものである。ARMAモデルの主な限界は、多くの金融時系列における重要な経験的現象であるボラティリティ・クラusteringを考慮しないことである。

ARIMAはARMAモデルのクラスを自然に拡張したもので、非定常な系列を定常な系列に還元することができる。ARIMA (Box 2013) は、将来のポイントを予測するために時系列データに適合させる。ZhongとEnke(Zhong and Enke 2017)はさらに、通常複数の入力変数を利用する統計的アプローチの別のグループを説明し、これらには線形判別分析(LDA)、二次判別分析(QDA)、および回帰アルゴリズムが含まれる。

2.3 機械学習を用いる市場予測

機械学習の金融市場の予測への適用は、広く研究されている(Shen, Jiang, and Zhang n.d.)

機械学習は大きく分けて教師あり学習と教師なし学習に分類される。教師あり学習では、モデルのパラメータを学習するためのラベル付けされた入力データと観測された出力データのセットを利用する。一方、教師なし学習では、ラベルのない出力データあるいは観測された出力データのみを利用する。教師あり学習の目標は、入力データを与えられた出力データに自動的に対応付けるアルゴリズムを学習させることである。訓練されると、機械は入力データ点を見て、予想される出力を予測することを学習するようになる。教師なし学習の目標は、与えられたデータセットのパターン、相関関係、またはクラスタを見つけるためにアルゴリズムを訓練することである。教師なし学習は、教師あり学習タスクの前段階としても機能する。

株価の方向性予測には、いくつかの機械学習手法が使用されてきた。単一決定木、判別分析、ナイーブベイズなどの単純な技術は、ランダムフォレスト、ロジスティック回帰、ニューラルネットワークなどの性能の良いアルゴリズムに取って代わられた(Ballings et al. 2015)。非線形、データ駆動、一般化しやすい特性を持つ、深層人工ニューラルネットワーク(ANN)の使用による多変量解析は、金融市場分析において支配的で人気のある分析ツールとなっている((Zhong and Enke 2017))。最近では、時系列予測において、深層ニューラルネットワークを適用することが注目され始めている(Bao, Yue, and Rao 2017)。

2.4 感情分析

感情分析とは、文や文章をpositive, negativeと判別するというタスクである。感情という言葉からは、悲しい、嬉しい、怒っているなどの複数の軸があると予測されるが、現在の多くの研究で扱っているのはpositive, negativeの2値あるいは、neutralを含めた3値である。

感情分析も、最近、株式市場分析に利用されるようになってきている(Bollen, Mao, and Zeng 2011)。これは、株式市場や上場企業に特化したニュース配信やSNS等への投資家の投稿などのテキストコーパスを自動分析することで、投資家たちの感情を分析し、株式の動向を予測するプロセスである。感情分析に用いられる技術は、主に機械学習アプローチと辞書ベースのアプローチに分けられ、さらに辞書ベースまたはコーパスベースのアプローチに分けられる(Bhardwaj et al. 2015)。

2.5 感情分析を用いた市場予測

Makrehchi, Shah, Liaoの論文(Makrehchi, Shah, and Liao 2013)では株式市場の主要イベント(大きな損失または利益)の前後および同時期のテキストをソーシャルメディアソース(例: twitterのツイート)から収集し、各ツイートに対応するハッシュタグ(ポジティブまたはネガティブ)を割り当て、将来のツイートのハッシュタグを予測するモデルを訓練することにより、他のベースラインのアプローチよりも大きなリターンがあることが判明し、成功した取引戦略を作成した。この研究はツイートの感情分析で予測し取引戦略を作ることができた。

Khedrなどの論文(Khedr et al. 2017)では、3社の株価を含むデータセットを用いて、市場や企業に関連する複数種類のニュースの感情分析と過去の株価から、将来の株式市場の動向を予測するために有効なモデルを構築し、誤差を小さくして予測精度を89.80%に向上させることを目指すものである。この研究はニュースの感情分析でいい予測精度を達成できた。

Wu, Zheng, Olsenの論文(Wu, Zheng, and Olson 2014)では「新浪财经」を実験プラットフォームとして選び、株式市場に関するオンライン意見投稿の文脈に応じたセンチメント分析を行い、新しいセンチメントオントロジーを開発した。この手法は、一般的なセンチメント分析を、サポートベクターマシンと一般化自己回帰条件付きヘテロスケダスティックス・モデリングに基づく機械学習アプローチに統合したものである。実証実験の結果、株価変動のトレンドと株式掲示板のセンチメントには確かな相関があり、特に投資家のセンチメントは、成長株とは対照的にバリュー株に強い影響を与えることがわかった。この研究はネットニュースプラットフォームでの投稿の感情分析において価格変動との相関性を示すことができた。

Mittalなど(Mittal and Goel n.d.)は、センチメント分析と機械学習の原理を応用して、世論感情と市場心理の相関関係を見出し、ツイッターのデータを使って世論感情を予測し、予測した感情と前日のダウ平均の値を使って株式市場の動きを予測し、75.56%の検証精度を達成した。この研究はツイートの感情分析と前日の株価などで株価変化の予測でいい精度を達成できたが、Khedrより精度がよくない。

Pagoluなど(Pagolu et al. 2016)はWord2vecとN-gramという2種類のテキスト表現を用いて、Twitterから抽出したツイートの国民感情を分析した結果、株価の上下とツイートの国民感情には強い相関があることがわかった。この研究もツイートの感情分析の結果と株価の変化との相関関係に関する研究である。

Araci(Araci 2019)は、金融分野のNLPタスクを解決するためのFinBERT言語モデルを提示し、次のことを示す。2つの金融センチメント分析データセットにおける現在の最新指標のそれぞれについて、FinBERTは、少ない学習セットを用い、モデルの一部のみを微調整した場合でも、最新の機械学習手法を上回る。この研究は金融関連の感情分析で相対的に新しいモデルを使用した。

Cuiなどの論文(Cui et al. 2021)では、中国語の全単語マスキングと、中国語の事前学習済み言語モデルを提案する。また、シンプルで効果的なモデルであるMacBERTを提案し、これらのモデルの有効性を示すために、10の中国語NLPタスクに対して大規模な実験を行った。実験結果は、MacBERTが多くのNLPタスクで最先端の性能を達成することを示しており、今後の事前学習済み言語モデルに関する研究の助けとなる可能性を持っている。この研究も相対的に新しいモデル—BERTを使った。また、中国語の資料を感情分析した研究である。

ただし、これらの先行研究の中には、最低限の実験、評価すらおこなっていないもの、実験の条件が明確になっていないもの、予測のために用いるデータが一般に入手できないもの、論文中で明らかな leakage があるものなど、質の低い論文が多かった。

そんな中で、(Jing, Wu, and Wang 2021)というCNNでの感情分析とテクニカル分析による指標を組み合わせてLSTMIによる株価予測を行う手法を提案し、上海証券取引所の株価予測をおこなう実験をおこなった論文を見つけた。従来手法との比較もおこなうなど最低限の評価もおこなっており、中国語SNSの感情分析を用いた中国市場に関する株価予想の論文の中では比較的引用数が多いので、研究を進めるにあたって、この論文の追試をおこなった上で、改善を提案することにした。

次章で(Jing, Wu, and Wang 2021)の研究を紹介するとともに、実験結果の再現を試みる。

2.6 市場シミュレーションによる評価

株価予測の評価指標については、よく時系列予測的にMAPEなどの数値の偏差による指標が使われていたが、それよりも、投資の結果によって評価すべきとの声もあり、ここでそれを紹介する。

Ding(Ding et al. 2015)は、Lavrenko(Lavrenko et al. n.d.)が提案した手法を紹介した。それは、株を始値で一定額毎日空売りするか買うかして、その日の終値で還元する。その二つの手法を予測値で選ぶとすると、株価の予測の評価手法になる。詳細は第4章で紹介する。

第3章 Jing(2021)の研究とその再現

本章では、本論文のベースとするJing(2021)の研究の詳しい説明と、その再現実験について述べる。Jing(2021)は感情分析を用いた市場予想の研究で、本論文でこの論文をベースに選んだのは、個人的に興味を持つ上海証券取引所の個別銘柄を対象にしていること、他の論文と比べて具体的に書かれているため再現が可能と考えられたためである。

3.1 Jing(2021)の研究の概要

Jing(2021)は深層学習手法とセンチメント分析モデルを組み合わせるハイブリッド予測手法を提案している。この手法は、データの前処理、投資家心理の分析、予測モデルの構築の3つの部分から構成されている。畳み込みニューラルネットワークに基づくセンチメント分析モデルを使ってオンラインソーシャルネットワークのテキストデータを分類し、センチメント分析結果と株価を組み合わせることにより、LSTMニューラルネットワークアプローチを適用して株価を予測する。中国語のソーシャルネットワークを扱った論文は多くないが、Jing(2021)はその中でも比較的引用が多い論文となっている。

Jingらの研究では、「上海証券取引所の各銘柄の翌日の終値をその日までの株式データ、および、その日までの eastmoney.com という株式関係の各銘柄ごとの掲示板（書き込みは中国語）を用いて予測する」という問題を扱っている。

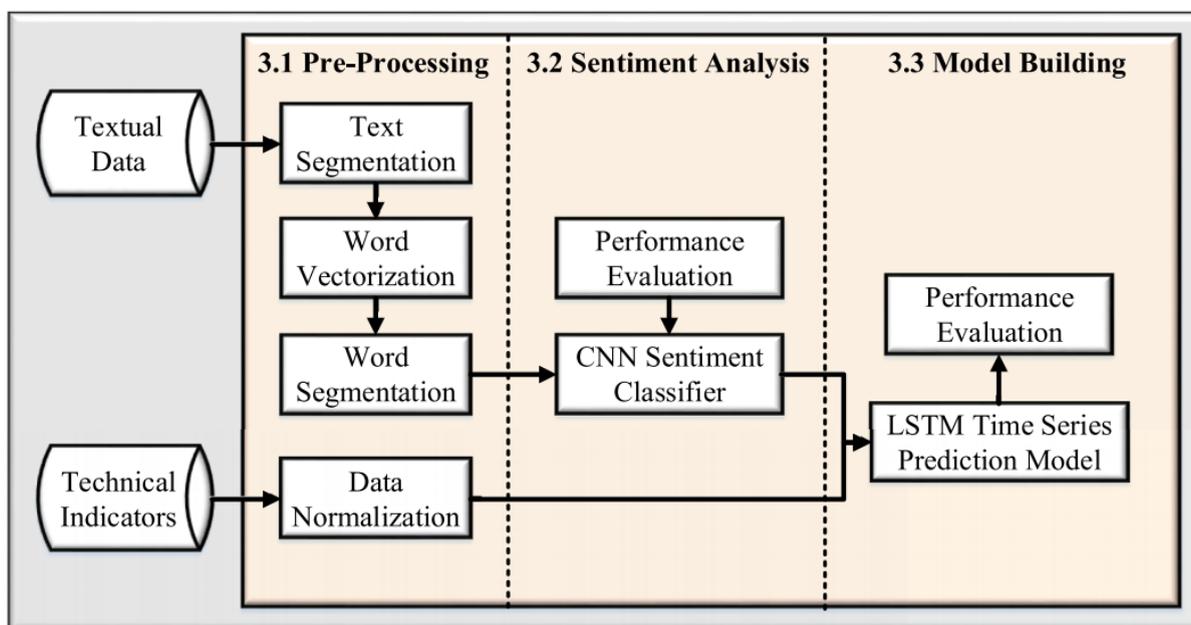


図3.1 ハイブリッドモデルの仕組み。(Jing, Wu, and Wang 2021) Fig 1より

図3.1はJingらの研究の仕組みを示したものである。テキストデータはテキストセグメンテーション、Word2vec、ワードセグメンテーション、CNN分類機を通過し、テクニカル指標はデータ正規化を経て、両結果が一緒にLSTM時系列予測モデルに入り、株価の終値を予測する。以下の節で、それぞれの詳細を説明する。

3.1.1 感情分析

Jing(2021)では中国語を対象にした感情分析の前処理の第一段階として、テキストデータを単語に分割する。例えば：

我们这种长线股民，每年用分红买一次而已，其它时间就是休息

という投稿から中国語を対象とした形態素解析を用いて、

我们 这种 长线 股民， 每年 用 分红 买 一次 而已， 其它 时间 就是 休息

のように単語ごとに分割する。

そして、ストップワード、つまり文の感情を表現するのに有用でない単語を削除する。中国語を対象にした自然言語処理では、ストップワードとしては、「的」、「了」、「和」、「是」、「就」、「都」などのどの文でも使われる単語が使われることが多い。さきほどの例では、「这种」(this の意)が該当するため、ストップワードの除去をおこなった結果は、

我们 长线 股民， 每年 用 分红 买 一次 而已， 其它 时间 就是 休息

となる。

前処理の第二段階では、このようにして得られた単語列をword2vecを適用して単語ベクトルの列に変換する。word2vecは、CBOW(Continuous Bag of Words)モデルを用いて単語のベクトル表現を得る一方、CBOWアーキテクチャは文脈に基づいて中心語を予測し、スキップグラムモデルは中心語に基づいて文脈を予測するものである。(Mikolov, Chen, et al. 2013; Mikolov, Sutskever, et al. 2013)word2vecモデルの構築にあたり、Wikipediaから取得したデータを用いて構築した中国語のコーパスを学習用として選択する。1文のテキスト特徴量がn語であると仮定すると、word2vecを使用した後、 $n \times k$ の2次元行列が得られる。行数nは文中の単語数、列数kは単語ベクトルの次元である。Word2Vecで扱う単語ベクトルの次元は扱う言語や、目的によって適した値が変わるが、最終的にはk=400を選択している。各単語には、コーパスに基づき、対応するベクトルが割り当てられる。ベクトル間のコサイン類似度がこれらの単語間の類似度に対応すると考えられる。

前処理したデータに対して、畳み込みニューラルネットワーク(CNN)ベースのセンチメント分析モデルを適用する。著者らは畳み込み層に128のフィルターを設定し、CNN分類器は図 3.2に示すように、データ入力、畳み込み層、最大プーリング層、完全連結層から構成されている。

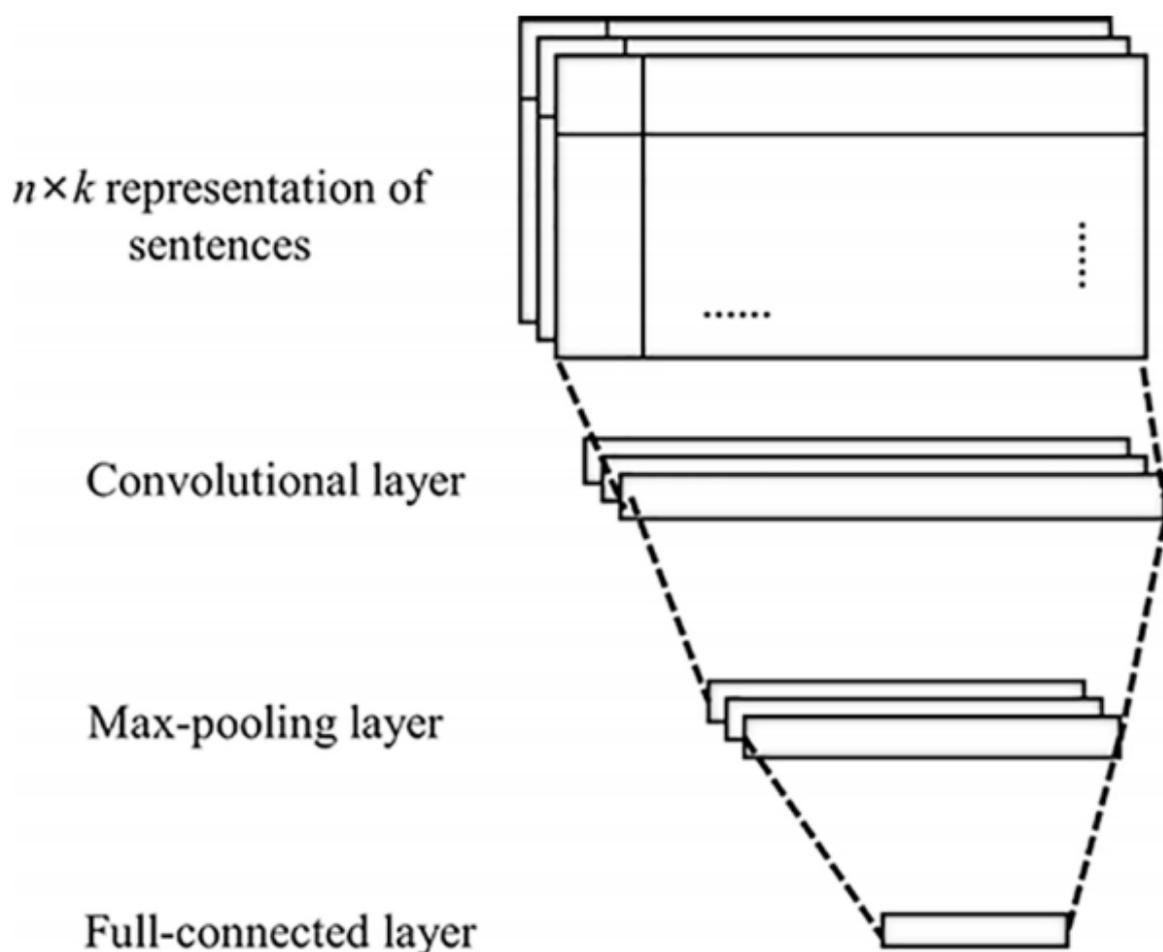


図 3.2 CNNによる感情分析モデルのコンセプト 入力サイズは $n \times k$ (Jing, Wu, and Wang 2021) のFig.2 より

入力層には, n 個の単語からなる未分類のテキスト t が与えられる. R^k は k 次元の単語ベクトル全体を表す集合であり, $w^i \in R^k$ は i 番目の単語ベクトルである. 以下のように w_i によって表現される.

$$w^{1:n} = w^1 \oplus w^2 \oplus \dots \oplus w^n$$

ここで, \oplus は連結演算子を表す.

次に, 畳み込み層では, サイズ $h \times k$ の畳み込みカーネルを入力層上でスライドさせる畳み込み演算を行い, 特徴マップ c を得る.

$$c_j = f(m \cdot w^{j:j+h-1} + b)$$

ここで, c_j は一般的処理後の j 番目の固有値, f は畳み込み非線形のカーネル関数であり, m は畳み込みカーネルである. ($m \in R^{h \times k}$, h は m 中の単語数, k は単語ベクトルの次元を表す) それに b はバイアスであり, いずれも学習段階で学習される.

最も重要な特徴を抽出するために、最大プーリング層ではマックスプーリング演算が適用される。

マックスプーリング処理後、出力特徴量 $v = [\hat{c}_1, \hat{c}_2, \dots, \hat{c}_k]$ は全結合層の入力である。最終層では、ソフトマックス分類器を適用し、分類結果を得る。

この場合、ラベルはネガティブとポジティブと定義する。次に、テキストデータの予測センチメントに基づいて、その日のプラスの書き込み個数とマイナスの書き込み個数の差を書き込みの総数日で割ってセンチメント係数 (SF^t) を計算する。

$$SF^t = \frac{num_+^t - num_-^t}{num^t}$$

表3.1 Jingらの論文における感情分析の各モデルの性能 (Jing, Wu, and Wang 2021) table 10より

	CNN	Logistic	SVM	RNN	LSTM
Average precision	0.875	0.79	0.823	0.83	0.844
Average recall	0.823	0.786	0.764	0.806	0.807
Average F-measure	0.8482	0.7880	0.7924	0.8178	0.8251

表3.1は、Jingらの論文における感情分析の各モデルの性能を示した。CNNの性能が一番高いことがわかる。

3.1.2 テクニカル指標の計算

金融市場の時系列分析では、市場動向や株価の予測に役立つ人気のテクニカル指標がいくつかある。Jingらの論文では、表 3.2 にあるように3つのタイプ(トレンド、モメンタム、ボリューム)のパラメータ設定が異なる16種類のテクニカル指標を用いている。これらのテクニカル指標は、 $[0, 1]$ の範囲にスケールされる。

3.1.3 LSTMを用いた予想

LSTMはリカレントニューラルネットワーク(RNN)の一つであり、メモリセルとゲートを適用し、長期情報を利用し、無駄な情報を無視して時系列データの関係性を発見することができる。Jingらの論文では、LSTMニューラルネットワークに基づき、センチメントファクターとテクニカル指標を組み合わせた時系列予測モデルを構築する。

提案する予測モデルは、図3.2 に示すように、時刻 t において、LSTMの j 番目のニューロンを定義する。 x_t は入力データ、 h_t は時刻 t における隠れ状態である。この予測モデルは、無意味な情報の影響を排除し、必要な長期的情報を蓄積する。各銘柄には、センチメント要因やテクニカル指標がモデル入力として適用され、1日後の終値が提案モデルの出力となる。LSTMを用いるにあたって、LSTM層の数、LSTM層の隠れユニットの数などいくつかのハイパーパラメータを設定する必要がある。学習レート、エポック数など学習に関係するハイ

表3.2 Jingらの論文におけるテクニカル指標のリスト (Jing, Wu, and Wang 2021) table5 より

Types	Technical indicators	Abbreviation
Trend indicators	Moving average (5)	MA(5)
	Moving average (30)	MA(30)
	Moving average (60)	MA(60)
	Exponential moving average (5)	EMA(5)
	Exponential moving average (30)	EMA(30)
	Exponential moving average (60)	EMA(60)
	Moving Average Convergence/ Divergence (6,15,6)	MACD(6,15,6)
	Moving Average Convergence/ Divergence (12,26,9)	MACD(12,26,9)
	Moving Average Convergence/ Divergence (30,60,30)	MACD (30,60,30)
	Momentum indicators	Relative Strength Index (14)
	Williams' %R (14)	WILLR(14)
	Momentum index (14)	MOM(14)
	Chande Momentum Oscillator (14)	CMO(14)
	Ultimate Oscillator (7,14,28)	ULTOSC (7,14,28)
Volume indicators	On Balance Volume	OBV
	Chaikin A/D Oscillator (3,10)	ADOSC(3,10)

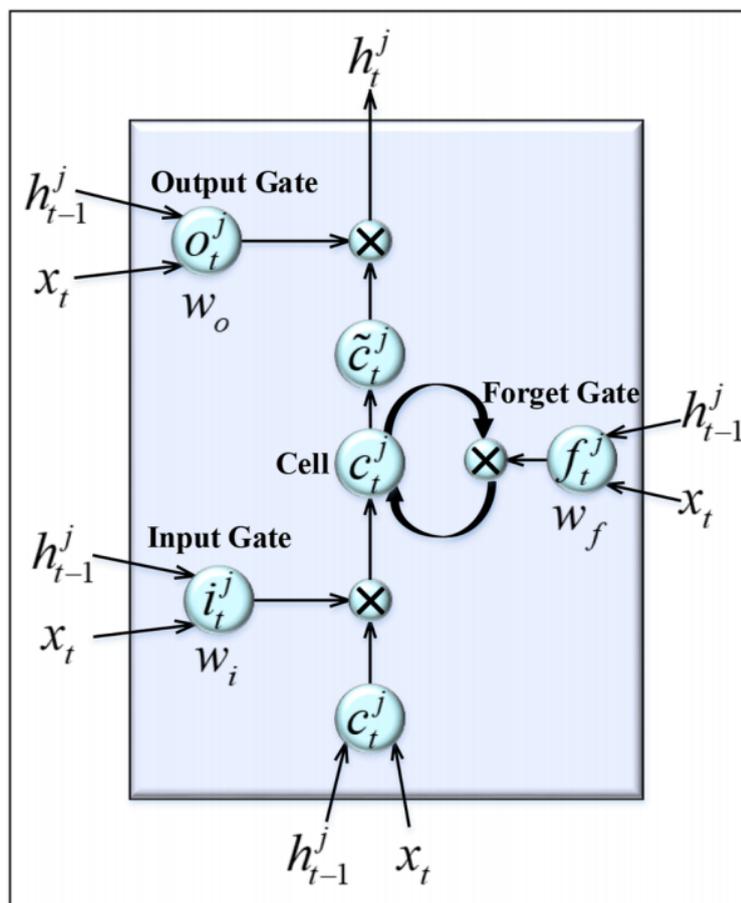


図 3.3 LSTMのコンセプト(Jing, Wu, and Wang 2021) Fig.3 より

ハイパーパラメータも含めて、グリッドサーチを用いてハイパーパラメータを決定している。各ハイパーパラメータ設定における提案モデルの性能は、Mean Absolute Percentage Errorで評価する。

3.1.4 実験と結果

上海株式取引所の6つの業種 (Finance, Manufacturing, Mining, Energy, Transportation, Construction)からそれぞれ5つの銘柄を選んで、2017年1月1日から2019年5月31日までの株価などのデータをトレーニングセットとし、2019年6月1日から7月31日までのデータをテストセットにして、学習と予測を行う。表3.3に含まれる30銘柄を対象としたと、論文に書かれている。SHとは上海証券取引所を指す。

ただし、実験結果の表では、600874.SHが外れて代わりに600795.SHが入っていた。複数箇所、600795.SHは出てくるので表3.3は誤りで600795.SHが正しいと思われる。

表3.3 予測する株のリスト (Jing, Wu, and Wang 2021) table 8より

Industry	Finance	Manufacturing	Mining	Energy	Transportation	Construction
Symbol	600000.SH 600036.SH 601099.SH 601229.SH 601788.SH	600060.SH 600475.SH 600660.SH 600771.SH 601777.SH	600028.SH 600188.SH 600508.SH 600583.SH 601899.SH	600027.SH 600617.SH 600874.SH 600917.SH 601016.SH	600004.SH 600115.SH 600350.SH 601188.SH 603223.SH	600502.SH 601117.SH 601618.SH 601800.SH 603007.SH

図3.3は、Jingらの論文に掲載されているで銘柄600000で提案手法によって得られた予測値と実際の終値のグラフである。誤差が大きいのが見える。

表3.4では、数個の期間において各株価予測モデルの性能を表したものになる²。LSTM+CNNのハイブリッドモデルの性能が一番いいというのがJingらの主張である。

表3.4 各モデルの株価予測の性能の比較 (Jing, Wu, and Wang 2021) table19より

Model	2015.11-2015.12	2019.6-2019.7	2020.3-2020.4	Average
Support Vector Regression	0.0866	0.0973	0.1043	0.0961
Genetic Algorithm-Support Vector Regression	0.075	0.0994	0.0923	0.0889
Convolutional Neural Networks	0.1058	0.0906	0.0811	0.0925
Genetic Algorithm- Convolutional Neural Networks	0.0658	0.0673	0.0723	0.0685
LSTM	0.0542	0.077	0.0713	0.0675
Hybrid Model (CNN-LSTM)	0.0413	0.0405	0.0528	0.0449

表3.5は、Jingらの論文で表3.3に含まれる30銘柄を対象した時のMAPEの数値を示すJingらの論文で、表3.1ではMAPEが平均0.0245、別に業種のなかからランダムに選んだ銘柄を用いた表3.4の実験でMAPEが平均0.0449を得て、他の手法と比較して小さいことを強調しているが、次の日の株価を予想したときの2-5%の誤差は必ずしも十分に小さいとは言えない。図3.4のグラフをみても、特に波動時の実データからの乖離が大きいのではないかと印象がある。

² ここでは、表3.3とは異なるランダムに選んだ30銘柄を使用したと書かれているが、具体的な銘柄の記載がない。

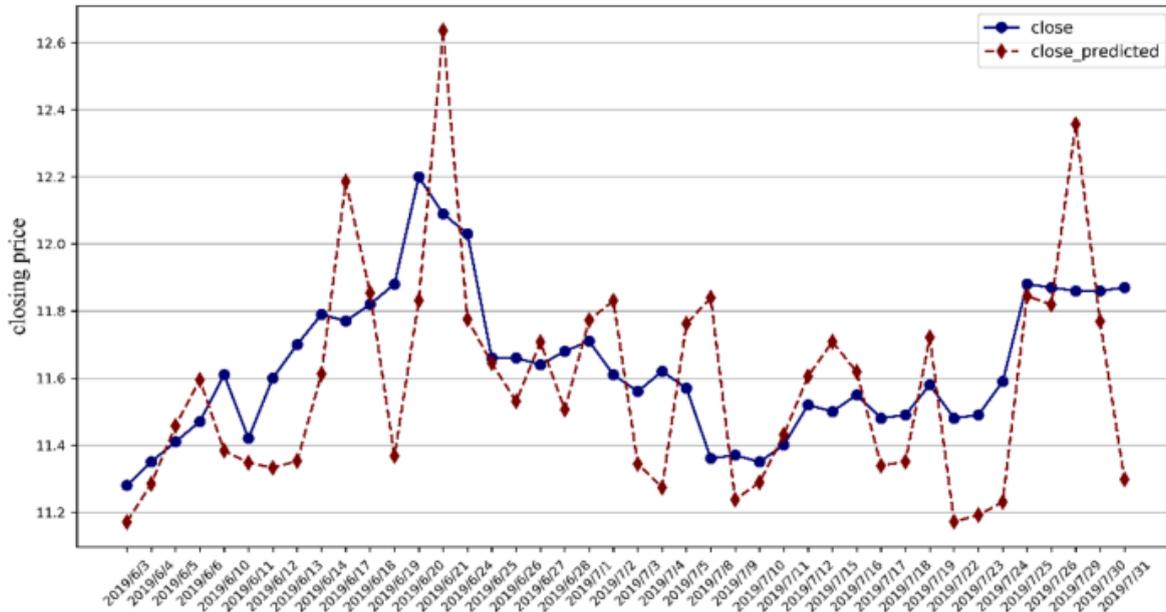


図 3.4 銘柄 600000の予測値と、実際の終値 ((Jing, Wu, and Wang 2021) のFig.4)

表 3.5 Jingらの論文でのMAPEの結果(Jing, Wu, and Wang 2021) table 17より

	Finance	Manufacturing	Mining	Energy	Transportation	Construction	Average
MAPE	0.0224	0.0244	0.0254	0.0247	0.0253	0.0247	0.0245

3.2 Jingらの論文の追試

機械学習系の論文では、使用したプログラムやデータが公開されていることが多いが、Jingらの論文については、プログラムもデータも公開されていない。また、Jingらの論文を参照している論文は多いが、Jingらの論文の結果を追試したものも見つからなかった。そのため、Jingらの論文に書かれている内容を確認するために、自分で該当するデータを取得した上で、プログラムを作成(一部は公開されているライブラリ等を利用して)追試した。以下に詳細を説明する。

3.2.1 scrapingによる株価データの取得

Jingらの論文ではDataYesから株価データを取得したが、DataYesは有料のソースなので、money.163.comから取得することにした。money.163.comは中国のファイナンスの情報サイトで、その中のページ(https://quotes.money.163.com/trade/sjysj_{株の番号}.html)には上海株式取引所の株の取引情報が載っている。それをBeautifulSoupというPythonのscraping用のライブラリを用いた自作プログラムで取得した。論文の主な結果で用いている2017.1 - 2019.7の期間を含むように、2016.1 - 2022.7の株価データを取得した。

30銘柄すべてで2016.1 - 2022.7の取引日すべてのデータが取得できることを期待したが、30銘柄のうち11銘柄で取引情報が取得できない取引日が存在した。それぞれについて取得のミスではなく理由があることを確かめた。たとえば、600475.SHの2017/2/24の欠損は取引停止によ

るものであり³, 601229.SHの2016/11/15以前のデータが存在しないのは, 該当銘柄(上海銀行上市)が2016/11/16に上場したためである.

株価データには, 指定した株式銘柄について, 取引日ごとの「始値 高値 安値 終値 損益額 損益率 出来高(枚) 売上高(人民元) 振動率(%) 手数(%) 増減率(人民元)」が含まれている. これらを元に, TA-Lib⁴という各種のテクニカル指標を計算するライブラリを用いて, Jingらの論文にあるテクニカル指標を計算した.

欠損データがある場合も, 欠損データがある取引日をデータから除いてテクニカル指標を計算した. また, たとえば, 2016/11/16に上場した 601229.SH について, MA(60)は2017/2/15まで計算できないため, それ以前の取引日はデータから取り除いている.

株価データの正規化について, Jingらの論文では, Table 9の説明にあるように, トレーニング期間と, テスト期間を通じての最大値と最小値を用いて[0,1]の範囲に正規化をおこなうことは書かれているが, テスト期間を正規化に用いるのは明らかに不適切と考えられる. たとえば, テスト期間の, ある日の終値が正規化後に1.0だったとすると, 翌日の終値が1.0を超えることがないことが保証されるからである. そのため, トレーニング期間の最大値と最小値を用いて補正をする. テスト期間では値が[0,1]の範囲であることは保証されないが, NNの入力は[0,1]の範囲であることを必要とはしないので, 問題はないと考える.

一般の投資において, 5日分の移動平均(MA5)と終値の大小関係を比較して次の日の売買戦略を決めるのは一般的であるが, 正規化をおこなうと別の項目は独立して正規化されるため, 別の項目ごとの大小関係の比較ができないという問題点がある. これは, たとえば終値を正規化した上で, 正規化した値の移動平均を求める等の方法で解決できるが, ここではJingらの論文に従った.

³ http://pdf.dfcfw.com/pdf/H2_AN201702150343171976_01.pdf

⁴ <https://ta-lib.org/>

日期	开盘价	最高价	最低价	收盘价	涨跌幅	涨跌幅(%)	成交量(手)	成交金额(万元)	振幅(%)	换手率(%)
2022-12-19	7.37	7.37	7.21	7.24	-0.11	-1.50	204,325	14,858	2.18	0.07
2022-12-16	7.25	7.35	7.23	7.35	0.11	1.52	317,046	23,217	1.66	0.11
2022-12-15	7.28	7.32	7.23	7.24	-0.08	-1.09	174,718	12,676	1.23	0.06
2022-12-14	7.37	7.37	7.26	7.32	0.00	0.00	161,806	11,835	1.50	0.06
2022-12-13	7.27	7.35	7.25	7.32	0.06	0.83	182,536	13,346	1.38	0.06
2022-12-12	7.31	7.36	7.23	7.26	-0.06	-0.82	267,086	19,464	1.78	0.09
2022-12-09	7.37	7.39	7.30	7.32	-0.06	-0.81	381,923	28,035	1.22	0.13
2022-12-08	7.32	7.39	7.31	7.38	0.04	0.55	255,518	18,798	1.09	0.09
2022-12-07	7.35	7.40	7.30	7.34	-0.02	-0.27	311,766	22,901	1.36	0.11
2022-12-06	7.32	7.39	7.30	7.36	0.00	0.00	305,503	22,445	1.22	0.10
2022-12-05	7.28	7.37	7.24	7.36	0.13	1.80	473,674	34,664	1.80	0.16
2022-12-02	7.25	7.25	7.17	7.23	0.01	0.14	257,220	18,535	1.11	0.09
2022-12-01	7.28	7.34	7.21	7.22	0.00	0.00	300,404	21,789	1.80	0.10
2022-11-30	7.24	7.30	7.22	7.22	-0.05	-0.69	323,470	23,433	1.10	0.11
2022-11-29	7.10	7.30	7.08	7.27	0.20	2.83	681,712	49,298	3.11	0.23
2022-11-28	7.10	7.10	6.98	7.07	-0.10	-1.39	378,732	26,659	1.67	0.13
2022-11-25	7.04	7.18	7.04	7.17	0.14	1.99	430,338	30,709	1.99	0.15
2022-11-24	7.06	7.14	7.03	7.03	-0.02	-0.28	215,345	15,226	1.56	0.07
2022-11-23	7.01	7.12	6.99	7.05	0.03	0.43	366,944	25,948	1.85	0.13
2022-11-22	6.89	7.04	6.89	7.02	0.14	2.03	334,245	23,320	2.18	0.11
2022-11-21	6.90	6.91	6.83	6.88	-0.03	-0.43	223,750	15,348	1.16	0.08
2022-11-18	6.99	7.00	6.91	6.91	-0.07	-1.00	226,629	15,746	1.29	0.08
2022-11-17	7.02	7.02	6.95	6.98	-0.05	-0.71	220,268	15,369	1.00	0.08
2022-11-16	7.03	7.06	7.01	7.03	-0.03	-0.42	173,981	12,233	0.71	0.06
2022-11-15	7.01	7.09	7.00	7.06	0.03	0.43	252,121	17,788	1.28	0.09
2022-11-14	6.98	7.09	6.96	7.03	0.09	1.30	437,774	30,827	1.87	0.15
2022-11-11	6.83	6.98	6.83	6.94	0.16	2.36	402,371	27,753	2.21	0.14
2022-11-10	6.75	6.80	6.74	6.78	-0.01	-0.15	126,010	8,533	0.88	0.04
2022-11-09	6.77	6.82	6.77	6.79	0.00	0.00	131,275	8,914	0.74	0.04
2022-11-08	6.83	6.83	6.77	6.79	-0.02	-0.29	152,829	10,371	0.88	0.05

図 3.5 money.163.comにおける600000という株の株価情報

3.2.2 scrapingによる掲示板書き込みデータの取得

Jingらの論文では eastmoney.com という中国の株式市場に関する情報サイトの銘柄別の掲示板への書き込みデータを、感情分析によって、数値化したものを株価予想の入力として用いている。eastmoney.com は中国語圏内の株式市場に関する情報サイトとしては、最大手のサイトの一つであるが、無料会員でも情報を交換できる銘柄ごとの掲示板があるのが特徴であり、毎日数多くの投稿がある。

eastmoney.com では、掲示板への書き込みデータは2010年のものまで残っているので、Jingらの論文で用いた掲示板への書き込みは取得できるが、利用可能な形で公開されていないので、scraping によりデータを取得する⁵。

上海証券取引所の株のすべての銘柄には、6桁の数字のidがつけられている。たとえば、「浦发銀行」は、600000 というidがつき、上海証券取引所であることを表す「.sh」をつけて「600000.sh」のように表記される。

eastmoney.com の掲示板では、この6桁の数字のidとページ番号(最新の書き込みページが1)を用いて、https://guba.eastmoney.com/list.{id}.f_{ページ番号}.html にアクセスすることで、掲示板への書き込みを取得できる。

例として、2022年12月に、「浦发银行(600000)」の最新の書き込みページ https://guba.eastmoney.com/list,600000,f_1.html をアクセスしたスクリーンショットを図 3.5 に示す。1ページにつき、8080個の書き込みに関する 阅读, 评论, 标题, 作者, 发帖时间 が得られ

⁵ 掲示板への書き込みは削除される可能性があるので、厳密に言えば、Jingが論文で用いたのと同じ期間の掲示板への書き込みデータを用いても、まったく同じデータを取得できるわけではない

る(図3.6の四角で囲った部分が対応している)。書き込みごとに、タイトルをリンクすると、書き込みごとのページにジャンプするが、本研究ではタイトルのみを用いる。



図 3.6 EastMoneyの銘柄別掲示板ページ

Jingらの論文で使われた30銘柄すべてについて、2016/1/1から2022/7/30までのページを取得した(1銘柄につき、数百から数千ページ)。人手で実行するのは無理なので、scrapingをおこなうプログラムを作成して実現した⁶。

当初は EastMoneySpider(<https://github.com/algosenses/EastMoneySpider>)という eastmoney.com をscraping することを目的に作成されたオープンソースプログラムを利用しようと試みたが、eastmoney.com の掲示板のデザインがEastMoneySpider開発時と異なっており、そのままでは使えないことがわかったので、requests と BeautifulSoup というPythonの定番のWebアクセスツールを用いて、scraping プログラムを自作して用いた。

当初は、5秒に1ページの取得を試みたが、100ページ取得したところで、一時的に取得できなくなるケースもあり30秒に1ページの取得に変更することで拒否されずに取得できるようになった。取得したデータに漏れもあったり、最終的には約2週間ですべての30銘柄すべてのページの書き込みデータを取得できた⁷。

3.2.3 感情分析

⁶ eastmoney.com のWebサーバには robots.txt が置かれていなかったため、常識的な範囲での頻度でのページ取得を試みた。

⁷ 厳密にいうと、あるページと次のページを取得する間に書き込みがあると、一部の投稿をスキップして取得することがある。ただし、数万の投稿に対して数個であり、許容することとした。

[wiki中国語コーパスを使用してword2vecに基づく単語ベクトルトレーニングモデルを実装する - wenyonet](#)をベースにword2vecを実行し、Jingらの論文に書いてあったchnsenticorpデータセット (15条消息) [chnsenticorp数据集及其处理 Reza.的博客-CSDN博客 chnsenticorp数据集](#) から入手したChnSentiCorp_htl_ba_6000.rarにある温泉に関するラベル付きのコメントデータでCNNモデルを学習させた。Songbo Tan, June 23, 2020, "ChnSentiCorp", IEEE Dataport, doi: <https://dx.doi.org/10.21227/yfwt-wr77>. からChnSentiCorpが取得できる。

Chnsenticorpは、6,000件のポジティブレビューと6,000件のネガティブレビューを含む、合計12,000件のレビューを持つホテルレビューデータセットである。Songbo Tanによって整理されたホテルコメントコーパスを選択し、文書数の異なる4つのコーパスセットから構成される。最初の3つのデータセットは、正文書と負文書の数が同じであるバランスコーパスであり、4番目のデータセットはバランスされていない。文書数は2,000から10,000まで増加した。その中にあるChnSentiCorp_htl_ba_6000.rarに3000個の正のラベルがついたコメントと3000個の負のラベルがついたコメントがある。この際、Jingらの論文では、バージョン等について書かれていないので完全に一致しているかどうかはわからない。

Wikipediaでは、<https://dumps.wikimedia.org/zhwiki/> から中国語版 Wikipedia の全文を公開しているので、2022年5月に当時の最新版を取得してword2vecのトレーニングに用いた。ただし、ここから取得できるのは最新版から8バージョン遡ったもの(4ヶ月前)のみであり、Jingが用いたデータとは異なっている(Jingはいつの時点での中国語版Wikipediaのデータを用いたのかを公開していない)。

感情分析には、<https://github.com/Feuoy/sentiment-analysis> という公開ソフトウェアを用いた。このソフトウェアには、Jingらの論文の提案手法と同等のword2vec適用後に convolution layer, maxpooling layer, full connected layer からなるNNを用いた感情分析をおこなうプログラムが TextCNN1dという名前で提供されている。ただし、ここではTextCNN1dをそのまま使わず、Jingらの論文に従った正規化をおこなう。

https://raw.githubusercontent.com/fxsjy/jieba/master/extra_dict/stop_words.txt とzhconv, jiebaの両ライブラリを使ってstop wordsの除去をおこなった。Jingらの論文では10-fold cross validationを用いて評価をおこなったが、<https://github.com/Feuoy/sentiment-analysis> ではsklearn.model_selection.train_test_splitを用いて、乱数でshuffleした全体の0.7をtrainに0.3をtestに割り当てている。本論文では、それをそのまま用いている⁸。

Jingらの論文のTable 10 に対応する結果は表3.6のようになっている。

表3.6 再現したCNNによる感情分析の精度

precision	0.8981477616187038
recall	0.9214094791767928
f1	0.9089405812702871

Jingらの論文と比べて大きな差はない結果が得られている。

⁸ 感情分析の精度を評価する場合には、10-fold cross validationを用いる方が望ましいが、ここでは学習結果を用いた株価予測の評価が目的なので、これでも問題ないと判断した。

3.2.4 LSTMを用いた予想

データを導入してから、求められている期日のデータを取り出し、最小値0～最大値1にスケールリングし、欠損値のある期日のデータを削除し、pytorchを用いてLSTMを構築し、optimizerにAdamを使い、手動によりハイパーパラメータを調節した。

Jingらの論文と同様に、感情分析の結果とテクニカル指標を用いた予測(以下の表ではLSTM)と、テクニカル指標のみを用いた予測(以下の表ではLSTM w/o sa)をおこなった。

3.2.5 対照手法

Jingは対照実験として

- Support Vector Regression
- Genetic Algorithm-Support Vector Regression Convolutional Neural Networks
- Genetic Algorithm- Convolutional Neural Networks LSTM
- Hybrid Model (CNN-LSTM)
-

をおこなったが、Support Vector Regression, Genetic Algorithm-Support Vector Regression Convolutional Neural Networks, Genetic Algorithm- Convolutional Neural Networks LSTMなどは、十分な情報が論文中に無く、実装に用いたプログラムも公開されていないため、再現できなかった。

一方で最も単純な予測法である

- 前の日の終値をそのまま次の日の終値として予測する(以下の表では yesterday)
- テクニカル指標の線形和を予測に用いて、最小二乗法で誤差を最小化する(以下の表では simple prediction)

などは試していなかったため、再現実験ではこの2つの方法を試した。

3.2.6 実験

再現実験の結果、Jingらの論文の Table 11-17について、可能な限り同じ条件で実験をおこなった結果を表3.8 - 表3.12に示す。Jingらの論文の Table 18は、Jingらがrandomに選んだ銘柄が記述されていないので再現は試みていない。そのため、表3.5に対応する結果は、指定の30銘柄のみに関しての実験した表 3.13 となる

表 3.7 Financeに関する株価予想のMAPE(SHは上海株式取引所を指す)

	600000.SH	600036.SH	601099.SH	601229.SH	601788.SH
LSTM	0.00718	0.0133	0.0184	0.0271	0.0177
Jingらの論文 の値	0.0177	0.0251	0.0215	0.0252	0.0225

表 3.8 Manufacturingに関する株価予想のMAPE

	600060.SH	600475.SH	600660.SH	600771.SH	601777.SH
LSTM	0.0124	0.0252	0.0103	0.0504	0.0298
Jingらの論文 の値	0.0208	0.0256	0.0246	0.0282	0.0225

表 3.9 Miningに関する株価予想のMAPE

	600028.SH	600188.SH	600508.SH	600583.SH	601899.SH
LSTM	0.0111	0.0113	0.00675	0.0119	0.0162
Jingらの論文 の値	0.0412	0.0425	0.0431	0.0333	0.0411

表 3.10 Energyに関する株価予想のMAPE

	600027.SH	600617.SH	600795.SH	600917.SH	601016.SH
LSTM	0.0086	0.0193	0.00821	0.00901	0.02
Jingらの論文 の値	0.0254	0.0259	0.0246	0.0268	0.0245

表 3.11 Transportationに関する株価予想のMAPE

	600004.SH	600115.SH	600350.SH	601188.SH	603223.SH
LSTM	0.0181	0.012	0.00603	0.0197	0.0927
Jingらの論文 の値	0.0251	0.0245	0.0236	0.0245	0.0289

表 3.12 Constructionに関する株価予想のMAPE

	600502.SH	601117.SH	601618.SH	601800.SH	603007.SH
LSTM	0.0182	0.00976	0.00848	0.0105	0.0276
Jingらの論文の値	0.0241	0.0292	0.0261	0.0197	0.0242

表 3.13 手法ごとの株価予想のMAPE (w/o sa が without sentiment analysis)

	Finance	Manufacturing	Mining	Energy	Transportation	Construction	Average
yesterday	0.0126	0.0183	0.0103	0.00963	0.0153	0.0108	0.0128
Simple prediction	0.0147	0.0259	0.0108	0.0109	0.0181	0.0136	0.0157
LSTM w/o sa	0.0164	0.0223	0.0109	0.0119	0.0327	0.0168	0.0185
LSTM	0.01678	0.0256	0.0115	0.013	0.0297	0.0149	0.0186
Jingらの論文の値	0.0224	0.0244	0.0254	0.0247	0.0253	0.0247	0.0245

この結果からみると、表3.13のSimple prediction (テクニカル指標の線形和で予測)の方が、Jingよりいい結果を出している。LSTMを使ったらかなり改善できた。LSTMを用いた時系列データの学習に失敗しているのではないかと考えられる。

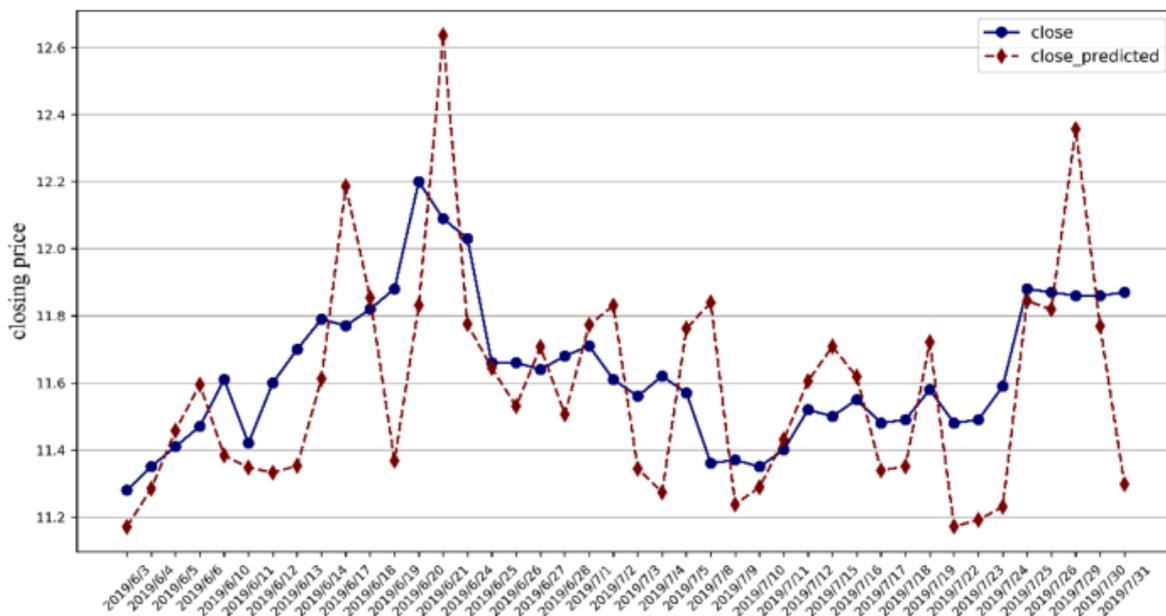


図3.4の再掲 (Jing, Wu, and Wang 2021)

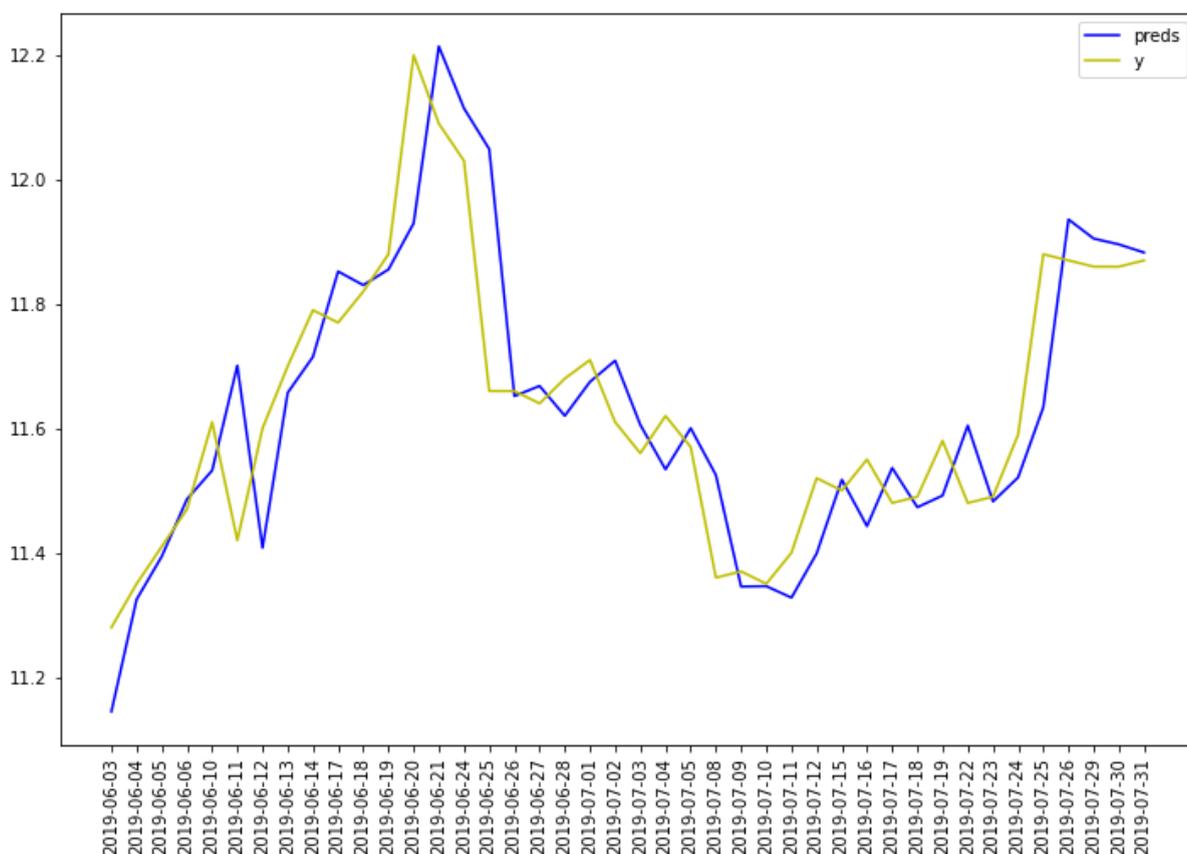


図3.7 予測値と実データの比較(600000.SH)

自分の再現結果のほうが誤差がないように見える。また、ほかの研究でも見られたように、次の日の予測値はその前日の終値に近いように見える。銘柄別でみると、601229.SHの銘柄については、再現結果の方が誤差が大きい。601229.SHについて、予測値と実データを比較したグラフを図3.8に示す。

図3.8をみると、2019-07-02の終値12.26から、2019-07-03の始値9.08に大きく変化していることがわかる。これが、誤差を大きくしていることが予想される。この異常な変化の原因を調べてみたところ、2019-7-2から2019-7-3にかけて、1株あたり、0.3株と0.45元の配当があったためであり、2019-07-02の終値から2019-07-03の始値の間の変化はこれで説明できることがわかった⁹。Jingらの論文では601229.SHの予測値の誤差は他の銘柄と同程度であり、どうしてこの影響を受けなかったのかわからない。このような配当による株価の変動は他の株式についても影響があると考えられるが、Jingらの論文ではこれらを考慮した補正をおこなっているという記述は見つけられなかった。

⁹[601229:上海銀行2018年年度权益分派实施公告 上海银行\(601229\) 公告正文 \(eastmoney.com\)](http://eastmoney.com)

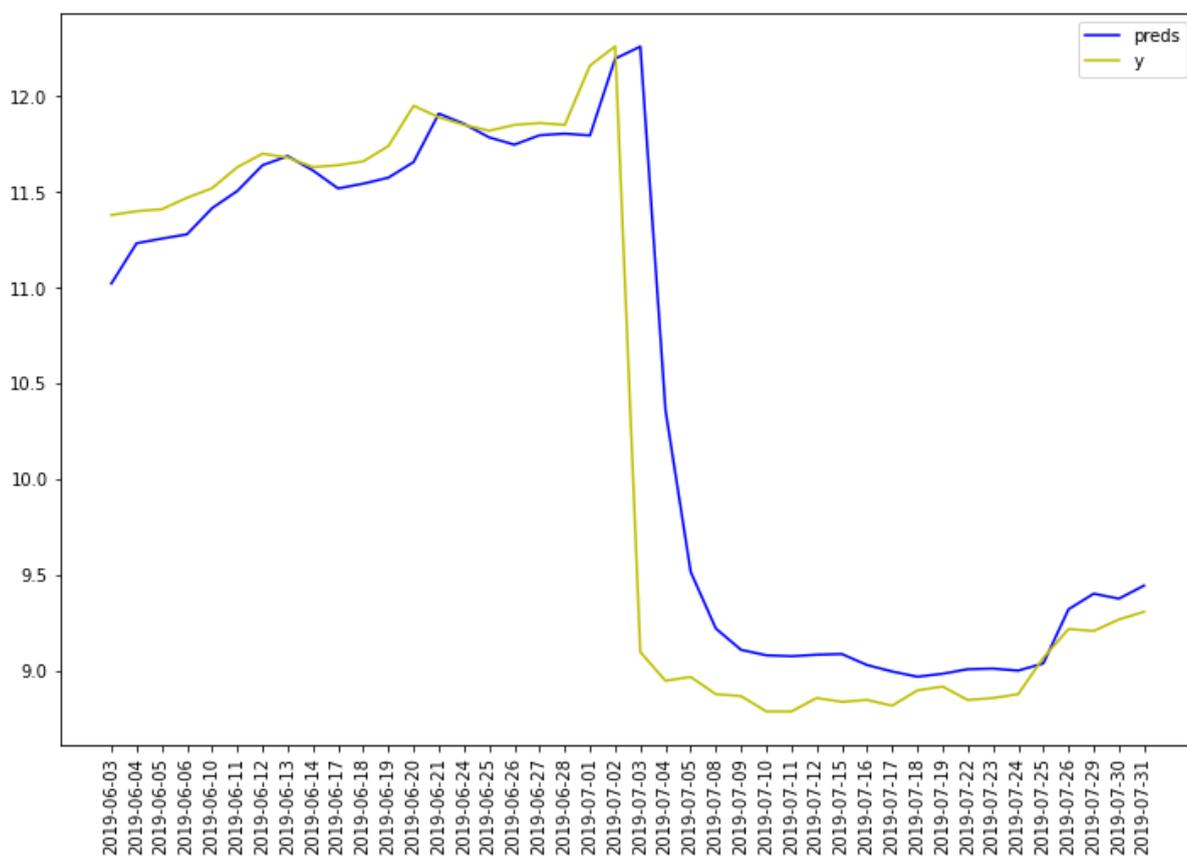


図 3.8 予測値と実データの比較(601229.SH)

3.2.7 考察

以上、本章ではJingらの論文の再現を試みて、Jingらの論文よりも良い結果を得たが、一方で、Jingらの提案する予測法をMAPEだけで評価すると前日の終値を予測値に用いるものを超えるのが難しいことがわかった。これは、MAPEを予測値の評価に用いることの限界を示していると考えられる。

Jingらの研究が主張する主な貢献は、感情分析を入れることにより株価予想の予測精度があがるということだったが、追試結果は向上が見られないという結果になった。感情分析の手法を改善することにより、株価予想精度の向上が期待されるので、いくつかの感情分析手法の改善を提案する。

次章で、予測の評価に市場シミュレーションを用いること、および感情分析においてほかの株に関する書き込みを除去すること、感情分析において相対的に新しいBERTモデルを適用することを提案する。また、予想に用いるハイパーパラメータの調整にJingらは、grid searchを用いたが、Optunaのようなハイパーパラメータ調整ツールを用いることも提案する。

第4章 提案手法

4.1 市場シミュレーションによる評価

前章では株価予想の評価として、実際の値と予測値のMAPEで評価をおこなった。その結果、元論文で提案されていた手法を含む複数の予測法の中で、元論文では比較対象にしていなかった前日の終値をそのまま次の日の終値と予測する方法が最も誤差が小さい予測方法という結果になった。しかし、前日の終値をそのまま次の日の終値と予測する方法が、株価予測の方法として意味があるとは思えないので、株価予測を評価するための別の評価指標を導入することを提案する。

終値予測値を元に、評価する指標として、(Lavrenko et al. n.d.)で以下の手法が提案されている。この手法は、(Ding et al. 2015)などでも評価に用いられている。

期間を通じての取引について、「毎日、1万ドル分の投資をおこなう。一日ごとの収益を期間を通じて総計を求める」。以下、毎日の取引についての説明である。

最も可能性の高いトレンドがプラスであれば、当システムは1万ドル分の株を購入する。任意の時点で1万ドル相当の株式を購入できる十分な信用があると仮定する。もう一つ的前提は、類似のバリユエーションによく見られる取引コストゼロである(利益さえ出れば、取引コストは各取引量を増やすことで容易に吸収できる)。購入後、システムは1時間在庫を保持する。その1日以内に売却して1%(100円)以上の利益を得ることができれば、すぐに売却する。その1日の終わりに、現在の買値で株を売る。

最も可能性の高いトレンドがマイナスであれば、アナリストは1万ドル相当の株式を空売りする(これは、後で安い価格で購入することを期待して、まだ持っていない株式を売却することを意味する)。ここでも、アナリストは1日間株を保有する。その日のうちに、空売り価格より1%低い価格で株を買うことができれば、システムはその株を買ってポジションをカバーする。その日の終わりに、アナリストは現在の市場価格で株を購入する。
(Lavrenko et al. n.d.)

この評価方法は、

- 手数料が0であるというかなり無理のある前提
- 始値や終値での売買がかならず成立するという前提
- このような買い方をする市場参加者がいることが、取引に影響を与えないという前提

など、市場のシミュレーションといっても、かなり大胆な仮定をおいたものになっている。株価予測をおこなった後に、最も都合よく取引が成立した時の収益とみなすのが適当と考えられる。

4.2 Optunaを用いたハイパーパラメータ調整

Optunaはベイズ最適化のライブラリである。Optunaを使うとき、ハイパーパラメータを一定の範囲内に設定し、その設定コードを学習コードと一緒に関数化し、その関数をOptunaで動かして、最適なパラメータが得られる。

主に実行時の履歴データに基づいて、次にテストすべきハイパーパラメータ値を決定する。このデータに基づいて、ハイパーパラメータが発生しやすい領域を推定し、その領域でハイパーパラメータ探索を試みることができる。新しい結果が得られると、この領域を更新して検索を継続する。更新の探索と評価のプロセスを何度も繰り返し、より性能の良いハイパーパラメータを得ることができる。具体的には、Optunaの最適化手法は、ベイズ最適化アルゴリズムのパーゼンツリー最適化手法に属するものである。

また、枝刈リアルゴリズムがあり、学習過程の早い段階で絶望的な試行を自動的に終了させる（自動早期停止機能(Akiba et al. 2019)）

ここで、Optunaで探索したハイパーパラメータの範囲を表4.1で示す。

表4.1 Optunaで探索したハイパーパラメータの範囲

Hyperparameter	Description	Range
Layers size	LSTMモデルの層数	(1,2,3,4,5)
Hidden units size	各層の隠れユニットの数	(10,30,50,70,90,110,130,150,170,190,210,230,250)
Learning rate	推定された誤差に対して、どの程度モデルを変更するか	(0.001~0,1)
Epochs size	LSTMが全体の学習を通過する回数	(10,20,30,40,50,60,70,80,90,100)

4.3 ほかの株の話の除去

書き込みが書かれている掲示板は、株によって分かれている。しかし、株Aの掲示板で株Bの話がある場合もある。例えば

浦发銀行の掲示板に、2022年12月8日に以下のような書き込みがあった。

「浙商银行是我的根据地」

これを日本語訳すると、「(浦发銀行)は好みではなく、(浙商银行)という同じく銀行株である株こそが本命」となる。この書き込みは浙商银行という株に関連するもので、「浙商银行は私のアジトだ」と言及している。これを受けて正か負かの感情の分析をしても、浦发銀行の掲示板にある以上、プログラムはそれを浦发銀行への評価と認定する。それはほかの株に関する書き込みが書かれた例である。

このように、ある株の掲示板にある書き込みを全部この株に関する書き込みとしたのに、実はその中でほかの株に関する書き込みがあり、それをそのまま感情分析に使えば結果に誤差が生じると考えられる。この誤差を排除するために書き込みの中からほかの株の名前が使われているかどうかについて調べ、その投稿を除くことにより該当株に関する投稿のみが残ることが期待される。

4.4 BERTを用いた感情分析

BERT(Devlin et al. 2018)は2018年にGoogleによって発表されたモデルであり、自然言語処理モデルとされたが、多くの領域で当時の最高水準のモデルとなった。中国語の感情分析にBERTを用いる先行研究もあり、(Li et al. 2021)では株式評論に関して適用している。感情分析の精度を高めることが、株価予想の精度の向上につながるかどうかは自明ではないが、Jingらの研究の感情分析をBERTを用いたものに変更することで、結果がどう変わるかを試みる価値はあると考えられる。

第5章 実験

5.1 市場シミュレーションによる評価

第3章でおこなったJingらの研究の再現でおこなった予測結果を対象にした市場シミュレーションの結果を示す。シミュレーションでは、毎日buyかsellのどちらかの行動を選択するものとする。第4章で説明したように、buyを選択した日は、始値で10000元分の株を買い終値で売るが、始値よりも2%高い値をつけたならば、終値まで持たずに即座に売るものとする。sellを選択した日は、始値で10000元分の株を空売りし、終値で買い戻すが、始値よりも1%低い値をつけたならば、終値まで待たずに即座に買い戻す。

表のsimple prediction,LSTM w/o sa,LSTM は、それぞれの方法による終値の予測値が、前日の予測値よりも高いならばbuyを選択、sellを選択した時の期間を通じた損益の和である。allbuyは毎日buyを選択した時の損益の和、allsellは毎日sellを選択した時の損益の和であり、averageはallbuyとallsellの平均、すなわちランダムにbuyとsellを選択した時の損益の和の期待値となり、前日の終値を次の日の終値の予測値とする場合(第3章のyesterday)の市場シミュレーションの結果に相当する。allmaxは最適なbuyとsellを「結果を見た上で」選択できる場合の損益の和となる。allmaxは実際に適用可能な戦略ということではなく、神の視点で未来が100%予測できた上で、この売買戦略を取れたとすると、この市場でどれだけ利益を上げられるかを見積もるための参考値として示した。longholdとは取引期間の始まりの時の始値で10000元買い、終わるときに終値で売るという戦略で得られる損益である。

表5.1 Finance1に関する株価予想の市場シミュレーションによる評価

	600000.SH	600036.SH	601099.SH	601229.SH	601788.SH
allbuy	329.2	311.2	-139.4	649.2	-188.8
allsell	-37.68	-386.1	-687.1	-564.8	-384.1
allmax	3110	3731	4753	2665	4726
simple prediction	264.6	-377.3	-790.3	-157.4	695.7
LSTM w/o sa	860.1	140.7	-994.6	436.4	-473.5
LSTM	745.7	-820.4	-687.1	-197.1	-654.4
longhold	626.7	674.5	948.3	-1746	376.1

表5.2 Manufacturingに関する株価予想の市場シミュレーションによる評価

	600060.SH	600475.SH	600660.SH	600771.SH	601777.SH
allbuy	-50.56	1101	-280.6	-1509	-1861
allsell	-360.3	-185.6	205.9	-340.5	-1139
allmax	3826	5427	3486	5755	59004.
simple prediction	-1438	1101	-175.9	-533.8	-1511
LSTM w/o sa	171.6	234.6	657.9	-518.8	166.7
LSTM	-607.5	327.1	-813.8	-53.1	-258.9
longhold	365	1119	320.7	-144	-2000

表5.3 Miningに関する株価予想の市場シミュレーションによる評価

	600028.SH	600188.SH	600508.SH	600583.SH	601899.SH
allbuy	-33.23	-444.9	-366.8	-1161	1546
allsell	175.8	445.8	206.1	1472	-541.1
allmax	2237	3623	2283	3405	5168
simple prediction	-130.3	-178.7	540.9	1474	368
LSTM w/o sa	-482.7	594.7	738	-1561	-323.8
LSTM	175.8	607.8	834.3	-214.3	1011
longhold	-312.5	-301.6	-504	-625	1091

表5.4 Energyに関する株価予想の市場シミュレーションによる評価

	600027.SH	600617.SH	600795.SH	600917.SH	601016.SH
allbuy	191.6	-970.4	-365.6	-127.3	-908.6
allsell	140.6	1753	701.3	359.4	503.2
allmax	3595	4429	7651	2624	3181
simple prediction	813.8	800.8	-29	-36.44	-981.7
LSTM w/o sa	643.7	938	541.4	-438.8	-908.6
LSTM	821.4	938.8	-579.1	-208.1	503.2
longhold	51.15	-1540	79.05	-323.9	-1119

表5.5 Transportationに関する株価予想の市場シミュレーションによる評価

	600004.SH	600115.SH	600350.SH	601188.SH	603223.SH
allbuy	826.2	-1141	-385.9	1203	-750.8
allsell	-1286	716.1	537.4	134.6	1142
allmax	5729	3552	2373	4762	4618
simple prediction	-237.5	-1309	424.4	128.1	-366.3
LSTM w/o sa	1316	387.2	245.9	1182	-750.8
LSTM	-732.3	815.1	312.4	234.6	-750.8
longhold	1229	-280.5	147.1	255.6	-3579

表5.6 Constructionに関する株価予想の市場シミュレーションによる評価

	600502.SH	601117.SH	601618.SH	601800.SH	603007.SH
allbuy	-1173	-942.8	78.52	28.76	-889.5
allsell	735.6	999.9	-164.2	706.3	781.9
allmax	4007	3373	2454	3472	4393
simple prediction	772.3	-632.4	-164.2	889.7	-1626
LSTM w/o sa	123.8	-893.3	-451.4	757.8	-1856
LSTM	528.8	155.5	-452.6	28.76	-1279
longhold	-866	-428.3	-166.7	0	-1097

表5.7 各領域と総体的な評価結果

	Finance	Manufacturing	Mining	Energy	Transportation	Construction	Average
allbuy	192.3	-519.9	-92.11	-393	-49.63	-579.6	-240.3
allsell	-412	-363.9	351.7	595.5	248.7	611.9	172.4
average	-109.8	-441.9	129.8	101.3	99.54	16.15	-33.95
simple prediction	-72.93	-511.6	414.8	113.5	-272	-152.1	-80.05
LSTM w/o sa	-62.46	142.4	-206.9	155.1	476.1	-609.6	-17.56
LSTM	-322.7	-281.2	482.8	295.2	-24.22	-207.2	-9.536
longhold	175.8	-67.83	-130.4	-570.5	-445.5	-511.7	-258.4

表5.7からいえることは、MAPEが小さかったyesterday (表5.7ではaverageが相当), simple predictionが市場シミュレーションの評価では良くなかった, 一方でLSTM, LSTM w/a はそれ以上の収益を上げているが, 結果として収益がマイナスになっている. また, LSTMがLSTMw/o saよりも良かったが, 感情分析を入れたことにより有意に向上したと主張できない差であると考えられる.

5.2 Optunaを用いたハイパーパラメータ調整

Optunaを用いたハイパーパラメータ調整では, Jingのgrid searchのように離散的な範囲でパラメータ値を調整するのではなく, 連続値での調整が可能である. そのため, 表 4.1 の範囲でのハイパーパラメータ調整をおこなった. 本番の評価では用いない600874.SHの銘柄を用いて, LSTMによる予測のMAPEが最小になるように, epoch数2000でOptunaを動かした結果, 得られたハイパーパラメータの値を表 5.8 に示す. なお, Learning rate, Epochs size については, Jingらの論文で使われているOptimizerとは異なるものと考えられるので, 比較するには意味がないと考えられる. Jingらの論文では5層という比較的多層のLSTMを用いていたが, Optunaによる調整の結果はよく使われる1層のLSTMが適しているという結果を示している.

表 5.8 ハイパーパラメータの説明と比較

Hyperparameter	Description	OptunaValue	JingValue
Layers size	LSTMモデルの層数	1	5
Hidden units size	各層の隠れユニットの数	70	20
Learning rate	推定された誤差に対して、どの程度モデルを変更するか	0.00221	0.01
Epochs size	LSTMが全体の学習を通過する回数	390	100

これで得られたハイパーパラメータを用いて、第3章と同様の株価予測をおこなった結果を表 5.9 - 表 15に示す。

表 5.9 Financeに関する株価予想のMAPE

	600000.SH	600036.SH	601099.SH	601229.SH	601788.SH
Optuna value	0.0097	0.022	0.0215	0.032	0.0186
Jingらの論文の値	0.0177	0.0251	0.0215	0.0252	0.0225

表 5.10 Manufacturingに関する株価予想のMAPE

	600060.SH	600475.SH	600660.SH	600771.SH	601777.SH
Optuna value	0.0166	0.0304	0.0127	0.0451	0.0287
Jingらの論文の値	0.0208	0.0256	0.0246	0.0282	0.0225

表 5.11 Miningに関する株価予想のMAPE

	600028.SH	600188.SH	600508.SH	600583.SH	601899.SH
Optuna value	0.0118	0.0133	0.007	0.0111	0.0168
Jingらの論文の値	0.0412	0.0425	0.0431	0.0333	0.0411

表 5.12 Energyに関する株価予想のMAPE

	600027.SH	600617.SH	600795.SH	600917.SH	601016.SH
Optuna value	0.00829	0.0197	0.00956	0.0098	0.0411
Jingらの論文の値	0.0254	0.0259	0.0246	0.0268	0.0245

表 5.13 Transportationに関する株価予想のMAPE

	600004.SH	600115.SH	600350.SH	601188.SH	603223.SH
Optuna value	0.0296	0.0151	0.0118	0.0284	0.0268
Jingらの論文の値	0.0251	0.0245	0.0236	0.0245	0.0289

表 5.14 Constructionに関する株価予想のMAPE

	600502.SH	601117.SH	601618.SH	601800.SH	603007.SH
Optuna value	0.023	0.00995	0.00876	0.00997	0.0334
Jingらの論文の値	0.0241	0.0292	0.0261	0.0197	0.0242

表5.15 領域的なMAPEの比較

	Finance	Manufacturing	Mining	Energy	Transportation	Construction	Average
yesterday	0.0126	0.0183	0.0103	0.00963	0.0153	0.0108	0.0128
Simple prediction	0.0147	0.0259	0.0108	0.0109	0.0181	0.0136	0.0157
LSTM w/o sa	0.0164	0.0223	0.0109	0.0119	0.0327	0.0168	0.0185
LSTM	0.0167	0.0256	0.0115	0.013	0.0297	0.0149	0.0186
Jingらの論文の値	0.0224	0.0244	0.0254	0.0247	0.0253	0.0247	0.0245
Optuna LSTM	0.0207	0.0267	0.012	0.0177	0.0223	0.017	0.0194
Optuna LSTM w/o sa	0.019	0.0259	0.0124	0.0199	0.0222	0.0151	0.0191

この結果、MAPEをみる限りは、Optunaを用いて得たハイパーパラメータを使ってもほとんど改善はなかたことがわかる。一方で、5.1節で提案した市場シミュレーションによる評価結果を表 5.16 に示す。

表5.16 各領域と総体的な評価結果(Optuna版)

	Finance	Manufacturing	Mining	Energy	Transportation	Construction	Average
allbuy	192.3	-519.9	-92.11	-393	-49.63	-579.6	-240.3
allsell	-412	-363.9	351.7	595.5	248.7	611.9	172.4
average	-109.8	-441.9	129.8	101.3	99.54	16.15	33.45
simple prediction	-72.93	-511.6	414.8	113.5	-272	-152.1	-80.05
LSTM w/o sa	-62.46	142.4	-206.9	155.1	476.1	-609.6	-17.56
LSTM	-322.7	-281.2	482.8	295.2	-24.22	-207.2	-9.536
longhold	175.8	-67.83	-130.4	-570.5	-445.5	-511.7	-258.4
Optuna LSTM w/o sa	-375.9	-123.2	278.6	527	198.7	75.14	96.73
Optuna LSTM	-303	-677.3	257.8	871.8	204.1	649	167.1

表 5.16では、市場シミュレーションによる評価ではOptunaを使って得たハイパーパラメータを用いた結果、収益に改善がみられたことがわかる。

5.3 ほかの株の話の除去

4.3節に従って他の株の名称を含む投稿を削除した上で、日毎、銘柄ごとの感情分析をおこなった入力を作成し、実験をした。表 5.17のように、MAPEのAverageは下がったが、分野によって下がり方が違うことは興味深い。Constructionで他の株を除去した結果、大きく改善されたことについては、どのような書き込みが除去されるのかは気になる。表5.18のように、投資シミュレーションの結果は悪い結果となった。LSTMより50%くらい悪くなった。この点からみると書き込みの除去に効果があるかどうかは判断できない。

表 5.17 ほかの株の話の除去に関するMAPEの領域的比較

	Finance	Manufacturing	Mining	Energy	Transportation	Construction	Average
LSTM(Optuna)	0.0207	0.0267	0.012	0.0177	0.0223	0.017	0.0194
51w/o_other(Optuna)	0.0152	0.0199	0.0106	0.0127	0.0204	0.0139	0.0154

表5.18 各領域と総体的な評価結果(withoutother版)

	Finance	Manufacturing	Mining	Energy	Transportation	Construction	Average
allbuy	192.3	-519.9	-92.11	-393	-49.63	-579.6	-240.3
allsell	-412	-363.9	351.7	595.5	248.7	611.9	172.4
average	-109.8	-441.9	129.8	101.3	99.54	16.15	33.45
simple prediction	-72.93	-511.6	414.8	113.5	-272	-152.1	-80.05
LSTM w/o sa(Optuna)	-375.9	-123.2	278.6	527	198.7	75.14	96.73
LSTM(Optuna)	-303	-677.3	257.8	871.8	204.1	649	167.1
LSTMw/o_other(Optuna)	-252.3	-185.3	189.6	545.5	18.75	-207.2	18.18
longhold	175.8	-67.83	-130.4	-570.5	-445.5	-511.7	-258.4

5.4 BERTを用いた感情分析

BERTの実装には, transformerの実装を用いた. モデルを読み込む. そのあとBERTTokenizerを試し, bbdata をmodelの入力にして output を得る.

BERTの感情分析 のposneg.csv に対する結果を表 5.19に示す.

表5.19 感情分析の結果の比較

	再現結果	Jing	BERT
precision	0.898	0.875	0.9552
recall	0.921	0.823	0.9861
f1	0.909	0.8482	0.9699

表 5.20 BERTの応用に関するMAPEの領域的比較

	Finance	Manufacturing	Mining	Energy	Transportation	Construction	Average
LSTM	0.0207	0.0267	0.012	0.0177	0.0223	0.017	0.0194
LSTMw/o_other	0.0152	0.0199	0.0106	0.0127	0.0204	0.0139	0.0154
BERT	0.0191	0.0212	0.0115	0.0106	0.0256	0.0139	0.0170
BERTw/o_other	0.0164	0.0205	0.011	0.0144	0.0196	0.013	0.0158

この表からみると、BERTを使わなく、ほかの株の話の除去を行った場合、改善があった。

表5.21 各領域と総体的な評価結果(bert版)

	Finance	Manufacturing	Mining	Energy	Transportation	Construction	Average
allbuy	192.3	-519.9	-92.11	-393	-49.63	-579.6	-240.3
allsell	-412	-363.9	351.7	595.5	248.7	611.9	172.4
average	-109.8	-441.9	129.8	101.3	99.54	16.15	33.45
simple prediction	-72.93	-511.6	414.8	113.5	-272	-152.1	-80.05
LSTM w/o_others (Optuna)	-252.3	-185.3	189.6	545.5	18.75	-207.2	18.18
LSTM(Optuna)	-303	-677.3	257.8	871.8	204.1	649	167.1
BERT(Optuna)	-238.2	-147.4	381.4	806.3	195.1	572.2	261.6
BERT w/o_others (Optuna)	130.3	-317.5	276.3	698.4	-1.355	368.2	192.4
longhold	175.8	-67.83	-130.4	-570.5	-445.5	-511.7	-258.4

市場シミュレーションの評価結果によると、BERTをほかの株に関する書き込みの除去がないバージョンに適用しても、改善があった。BERTバージョンにほかの株に関する書き込みの除去を応用したら改善がなかった。BERTをLSTMバージョンに応用したら改善があった。

第6章 考察

この研究では、ソーシャルメディアへの投稿とテクニカル指標を用いた株価予想を行った。Jingらの論文の再現を試みて、さらに提案した改善案についての実験もおこなった。再現を試みたがJingらの論文とは異なる結果を得た。Jingらの論文でどのようなOptimizerが使われたなどの詳細がわかっていないという点はあるが、予測精度の低さから考えて、Jingらの論文でLSTMの学習に失敗している可能性もあると考えている。

第3章の予測の図からみると、昨日の結果に近い予測値になって、MAPEという指標の意味に疑問を持つようになり、新たな評価基準として、Lavrenkoの論文の投資シミュレーションによる評価がより適切ではないかと考え、それをもとに実験した。その結果、Jingのパラメータでの予測でも株を長持ちよりいい結果であるのが確認された。

Optunaに関する結果については、Jingの結果より良い結果になった。Jingらの研究ではNum layers が5で、hidden_sizeが20で、learning rateが0.01(再現実験では0.002)、Epoch sizeが100であった。Optunaで得たハイパーパラメータに関して、Num layers が1で、hidden_sizeが70で、learning rateが0.00221で、Epoch sizeが390である。それはOptunaの使用によって、ハイパーパラメータがよりいい値になり、その結果、MAPEは改善しなかったものの、市場シミュレーションによる評価では改善がみられた。

ほかの株に関する書き込みの除去は、MAPEについては改善したものの、市場シミュレーションの評価結果で改善が見られなかった。その掲示板の株に関するものではない書き込みを除去すること自体は、株価予想の精度を上げることは間違いないと思うので、今回の結果についてはより考察が必要になると思われる。

BERTを用いることで、結果が向上した。BERTは、LSTMよりも新しく自然言語処理でよく使われるモデルであり、感情分析の精度を高めることができ、その結果株価予想の精度も向上した。しかし、BERTバージョンを用いる場合、他の株に関する投稿を削除することでMAPEの結果が悪化した。市場シミュレーションの評価結果について、他の株に関する投稿を削除した場合、BERTを加えることで結果が悪化した。今回の結果についてはより考察が必要になると思われる。

この研究で足りなかった点は、BERTの株価予想への応用の可能性とアンサンブルの可能性についてだと思う。BERTは時系列データの処理にも可能なので、試す価値もあると思う。またアンサンブルでは、たくさんのモデルを同時に応用し、その精度を一つのモデルより高くできるので、期待できるものだと考える。

全体として、先行研究はあるが、完全な再現がほぼ不可能であり、再現性がなさすぎの点があった。また、中国語でのオープンデータが少なすぎの面があり、そこを探すに手間がかかった。次の日の株価予測というテーマは斬新ではないが、やはり難易度が高かった。

謝辞

本研究に際して様々なご指導を頂きました田中哲朗准教授に心より御礼申し上げます。先生と一緒に環境構築並びにコーディングを手伝っていただいたこともあり、本当に感謝しております。また、ミーティング等で助言をいただいた田中研究室の皆様、特に博士課程の高岡様、私の発表を聞いて適切なコメントをくださった同じゼミの金子研究室の皆様にも感謝いたします。

参考文献

- Abu-Mostafa, Yaser S., and Amir F. Atiya. 1996. "Introduction to Financial Forecasting." *Applied Intelligence* 6 (3): 205–13.
- Akiba, Takuya, Shotaro Sano, Toshihiko Yanase, Takeru Ohta, and Masanori Koyama. 2019. "Optuna: A Next-Generation Hyperparameter Optimization Framework." In *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2623–31. KDD '19. New York, NY, USA: Association for Computing Machinery.
- Araci, Dogu. 2019. "FinBERT: Financial Sentiment Analysis with Pre-Trained Language Models." *arXiv [cs.CL]*. arXiv. <http://arxiv.org/abs/1908.10063>.
- Arévalo, Rubén, Jorge García, Francisco Guijarro, and Alfred Peris. 2017. "A Dynamic Trading Rule Based on Filtered Flag Pattern Recognition for Stock Market Price Forecasting." *Expert Systems with Applications* 81 (September): 177–92.
- Ballings, Michel, Dirk Van den Poel, Nathalie Hespeels, and Ruben Gryp. 2015. "Evaluating Multiple Classifiers for Stock Price Direction Prediction." *Expert Systems with Applications* 42 (20): 7046–56.
- Bao, Wei, Jun Yue, and Yulei Rao. 2017. "A Deep Learning Framework for Financial Time Series Using Stacked Autoencoders and Long-Short Term Memory." *PloS One* 12 (7): e0180944.
- Bhardwaj, Aditya, Yogendra Narayan, Vanraj, Pawan, and Maitreyee Dutta. 2015. "Sentiment Analysis for Indian Stock Market Prediction Using Sensex and Nifty." *Procedia Computer Science* 70 (January): 85–91.
- Bollen, Johan, Huina Mao, and Xiaojun Zeng. 2011. "Twitter Mood Predicts the Stock Market." *Journal of Computational Science* 2 (1): 1–8.
- Box, George. 2013. "Box and Jenkins: Time Series Analysis, Forecasting and Control." In *A Very British Affair: Six Britons and the Development of Time Series Analysis During the 20th Century*, edited by Terence C. Mills, 161–215. London: Palgrave Macmillan UK.
- Cui, Yiming, Wanxiang Che, Ting Liu, Bing Qin, and Ziqing Yang. 2021. "Pre-Training With Whole Word Masking for Chinese BERT." *IEEE/ACM Transactions on Audio, Speech, and Language Processing* 29: 3504–14.
- Devlin, Jacob, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. 2018. "BERT: Pre-Training of Deep Bidirectional Transformers for Language Understanding." *arXiv [cs.CL]*. arXiv. <http://arxiv.org/abs/1810.04805>.
- Ding, Xiao, Yue Zhang, Ting Liu, and Junwen Duan. 2015. "Deep Learning for Event-Driven Stock Prediction." In *Twenty-Fourth International Joint Conference on Artificial Intelligence*. <https://www.aaai.org/ocs/index.php/IJCAI/IJCAI15/paper/viewPaper/11031>.
- Fama, Eugene F. 1970. "Efficient Capital Markets: A Review of Theory and Empirical Work." *The Journal of Finance*. <https://doi.org/10.2307/2325486>.
- Fu, Tak-Chung, Fu-Lai Chung, Robert Luk, and Chak-Man Ng. 2005. "Preventing Meaningless Stock Time Series Pattern Discovery by Changing Perceptually Important Point Detection." In *Fuzzy Systems and Knowledge Discovery*, 1171–74. Springer Berlin Heidelberg.
- Jing, Nan, Zhao Wu, and Hefei Wang. 2021. "A Hybrid Model Integrating Deep Learning with Investor Sentiment Analysis for Stock Price Prediction." *Expert Systems with Applications* 178 (September): 115019.
- Khedr, Ayman E., Faculty of Computers and Information Technology, Future University in Egypt, S.E.Salama, and Nagwa Yaseen. 2017. "Predicting Stock Market Behavior Using

- Data Mining Technique and News Sentiment Analysis.” *International Journal of Intelligent Systems and Applications* 9 (7): 22–30.
- Lavrenko, Victor, Matt Schmill, Dawn Lawrie, Paul Ogilvie, David Jensen, and James Allan. n.d. “Mining of Concurrent Text and Time Series.” Accessed December 20, 2022. http://www.cs.cmu.edu/~dunja/KDDpapers/Lavrenko_TM.pdf.
- Li, Mingzheng, Lei Chen, Jing Zhao, and Qiang Li. 2021. “Sentiment Analysis of Chinese Stock Reviews Based on BERT Model.” *Applied Intelligence* 51 (7): 5016–24.
- Makrehchi, Masoud, Sameena Shah, and Wenhui Liao. 2013. “Stock Prediction Using Event-Based Sentiment Analysis.” In *2013 IEEE/WIC/ACM International Joint Conferences on Web Intelligence (WI) and Intelligent Agent Technologies (IAT)*, 1:337–42.
- M, Hiransha, Gopalakrishnan E. A., Vijay Krishna Menon, and Soman K. P. 2018. “NSE Stock Market Prediction Using Deep-Learning Models.” *Procedia Computer Science* 132 (January): 1351–62.
- Mikolov, Tomas, Kai Chen, Greg Corrado, and Jeffrey Dean. 2013. “Efficient Estimation of Word Representations in Vector Space.” *arXiv [cs.CL]*. arXiv. <http://arxiv.org/abs/1301.3781>.
- Mikolov, Tomas, Ilya Sutskever, Kai Chen, Greg Corrado, and Jeffrey Dean. 2013. “Distributed Representations of Words and Phrases and Their Compositionality.” *arXiv [cs.CL]*. arXiv. <https://proceedings.neurips.cc/paper/2013/hash/9aa42b31882ec039965f3c4923ce901b-Abstract.html>.
- Mittal, Anshul, and Arpit Goel. n.d. “Stock Prediction Using Twitter Sentiment Analysis.” Accessed February 5, 2023. <http://cs229.stanford.edu/proj2011/GoelMittal-StockMarketPredictionUsingTwitterSentimentAnalysis.pdf>.
- Naseer, Mehwish, and Dr Yasir Bin Tariq. 2016. “The Efficient Market Hypothesis: A Critical Review of the Literature.” <https://papers.ssrn.com/abstract=2714844>.
- Nguyen, Thien Hai, Kiyooki Shirai, and Julien Velcin. 2015. “Sentiment Analysis on Social Media for Stock Movement Prediction.” *Expert Systems with Applications* 42 (24): 9603–11.
- Pagolu, Venkata Sasank, Kamal Nayan Reddy, Ganapati Panda, and Babita Majhi. 2016. “Sentiment Analysis of Twitter Data for Predicting Stock Market Movements.” *2016 International Conference on Signal Processing, Communication, Power and Embedded System (SCOPES)*. <https://doi.org/10.1109/scopes.2016.7955659>.
- Park, Cheol-Ho, and Scott H. Irwin. 2007. “What Do We Know about the Profitability of Technical Analysis?” *Journal of Economic Surveys* 21 (4): 786–826.
- Shen, Shunrong, Haomiao Jiang, and Tongda Zhang. n.d. “Stock Market Forecasting Using Machine Learning Algorithms.” Accessed January 5, 2023. <http://masters.donntu.ru/2015/fknt/pozhydaev/library/article3.pdf>.
- Wu, Desheng Dash, Lijuan Zheng, and David L. Olson. 2014. “A Decision Support Approach for Online Stock Forum Sentiment Analysis.” *IEEE Transactions on Systems, Man, and Cybernetics* 44 (8): 1077–87.
- Zhong, Xiao, and David Enke. 2017. “Forecasting Daily Stock Market Return Using Dimensionality Reduction.” *Expert Systems with Applications*. <https://doi.org/10.1016/j.eswa.2016.09.027>.