

キーワード検索数とツイートの情報を用いた ビットコイン価格の騰落予測

Bitcoin price prediction using keyword search volumes and tweet information

松田周也¹ 原尚幸¹
Shuya Matsuda¹ Hisayuki Hara¹

¹ 同志社大学 文化情報学部

¹ Faculty of Culture and Information Science, Doshisha University

Abstract: In this paper, we propose an LSTM for predicting Bitcoin price using Google Trends data and sentiment scores of news and tweets. We used sentiment scores of news weighted by the number of news as inputs. We also used sentiment scores of tweet sentiment scores weighted by tweet information, such as the number of likes, the number of retweets and the number of followers and used them as inputs. The results show better performance of the proposed method than using the non-weighted sentiment scores of news and tweets as inputs.

1 はじめに

近年、テキストデータの取得技術、解析技術双方の進歩に伴い、テキストマイニングは様々な分野に応用されるようになった。テキスト情報と市場動向の関係を考察する金融テキストマイニング技術も、新たな展開を見せている。

和泉ら [1] は、株価変動の要因分析におけるニュース記事のテキストデータ有用性を示している。和泉ら [2] は、テキストデータ内の語句の出現頻度と価格変動の関連を分析するための CPR 法という手法を提案し、株価の月次変動の分析におけるニュース記事のテキストデータの有用性を示している。

また、テキストデータから感情分析によって算出された感情スコア¹を市場動向の分析に用いる研究も多く見られるようになった。投資判断の際にセンチメント指標があるように、感情スコアは金融商品価格の変動を分析する際に有効であると考えられる。深層学習の登場により感情スコアの推定精度が向上したことから、感情スコアの金融分野への応用は国内外で注目されている。

五島ら [3] は、深層学習を用いて算出したニュース記事の感情スコアを用いて、株価変動との関連性について分析を行い、ニュース記事が株価に影響を与えていることを示している。Batra et al.[4] は、2010 年から 2017 年の Apple 社の株価と Twitter のツイートの感情スコアを説明変数に用いて機械学習によって予測モデルを

構築したところ、価格データのみを説明変数とするモデルよりも価格騰落の予測精度が向上することを示している。Kalyani et al.[5] は、2014 年 5 月 1 日から 2015 年 4 月 30 日までのベトナムの株価に関するニュース記事の感情スコアを用いて、機械学習で予測モデルを構築し、翌日の価格騰落の予測に関しては、価格データのみを用いたモデルよりも高い予測精度が得られることを示している。Nayak et al.[6] は、2014 年から 2015 年までのインドの企業の株価に関するニュースの感情スコアとツイートの感情スコアを同時に用いて機械学習でモデル構築することにより、価格データのみを用いた予測モデルよりも翌日の騰落予測の精度を高められることを示している。

このような、テキスト情報を用いて株価を予測する手法は、近年、ビットコイン価格の予測にも適用されるようになってきている。Lamon et al.[7] は、2017 年 9 月 24 日から 2017 年 11 月 30 日のニュースの見出しの感情スコアとツイートの感情スコアを用いて機械学習によってビットコイン価格の予測モデルの構築を行い、価格データのみを用いたモデルよりビットコインの翌日の価格騰落の予測精度を高められることを示している。Karalevicius et al.[8] では、2014 年 1 月から 2017 年 9 月のビットコインに関連したニュース記事の感情スコアとビットコインの価格に関連があり、ビットコインの日間騰落予測モデルの精度向上に利用できることが示されている。Galeshchuk et al.[9] は、2016 年 2 月 1 日から 2016 年 2 月 29 日のビットコインに関連したツイートの感情スコアを用いて深層学習を用いて予測

¹感情分析とは、人工知能を用いてテキストを自然言語処理し、感情を定量的に評価する手法である。感情スコアとはその出力である。

モデル構築することで価格データのみでの騰落予測モデルよりビットコインの翌日の騰落予測の精度が向上することを示している。Kinderis et al.[10] は、2013年から2017年のツイートの感情スコアとニュース記事の感情スコアを用いて深層学習によって構築した予測モデルが、価格データのみを用いるよりも翌日の価格騰落の予測精度が高くなることを示している。

本稿でも、Kinderis et al.[10] にならい、ニュース記事の感情スコアとツイートの感情スコアを説明変数として使用し、深層学習を用いて翌日のビットコイン価格の騰落を予測することを考えていくが、本稿で考えるモデルと上述の先行研究のモデルには以下の4つの相違点がある。

Kinderis et al.[10] は、ニュース記事として仮想通貨ニュースサイトである Coindesk の記事を用いている。しかし、Coindesk のみからビットコインに関するニュース記事を取得すると、ビットコインに対してポジティブなニュースが多くなるという偏りが生じることが知られているため、Bloomberg のニュース記事を用いることで精度の向上が期待できる可能性を指摘している。そこで、本稿では全てのニュースサイトのニュース記事を取得できる Bloomberg のニュース記事を用いる。

また、Baig et al.[11] は、Google トレンドで取得したビットコインの検索数のデータ（以下、Google トレンドのデータとする）を用いることでビットコインの価格変動をパターン分けできることを示している。このことは、Google トレンドデータがビットコインの価格変動に対して説明力をもつこと示唆している。そこで、本稿では、先行研究で説明変数として用いられたツイートやニュースの感情スコアに加え、Google トレンドのデータも説明変数に用いることによってさらなる精度の向上を目指す。

近年、ソーシャルネットワークサービスにおいては、インフルエンサーの影響力が非常に大きいことから、被リツイート（以下、RT とする）数・いいねの数・フォロワー数なども騰落予測に影響を与えると考えるのはひとつの可能性である。そこで、本稿では、ビットコインに関連したツイートの感情スコアを算出する際に、「RT 数」「いいねの数」「フォロワー数」を用いて重み付けを行い、予測モデルに用いる。また、ニュース記事の感情スコアも、その日のニュースの数で重み付けを行ったものを予測モデルに用いる。

さらに、先行研究では英語のニュースやツイートのテキストデータを用いて分析が行われていたが、日本の仮想通貨保有率は世界の中で最も高く、加えて、ビットコイン取引の約半数が日本円で行われているという現状を踏まえ（図1・図2参照）、ビットコインに関連した日本語のニュース記事とツイートのデータを用いることとする。

本稿では、日本語のニュース記事の重み付き感情ス




図 1: 仮想通貨の保有率 ([12] を参考に作成)




図 2: 国別ビットコイン取引量 ([13] を参考に作成)

コア、日本語のツイートの重み付き感情スコア、Google トレンドのデータを用いて、既存のビットコインの騰落予測手法の改良を目指す。

2 深層学習を用いたビットコイン価格の騰落予測モデル

2.1 データ概要

本研究で使用したデータは、CoinMarketCap²で提供されているビットコイン価格の日次データ、Bloomberg で提供されているビットコインに関する日本語のニュース記事、Twitter 社が提供している API を用いて取得した「ビットコイン」という語を含むツイート、それを投稿したアカウントに関する情報、Google 社が提供している Google トレンドの「ビットコイン」の検索数に関するデータである。いずれのデータも、データ期間は 2020 年 6 月 26 日から 2020 年 10 月 17 日までの 114 日間である。図 3 に 2020 年 6 月 26 日から 2020 年 10 月 17 日までのビットコインの日次価格の推移を示す。図 3 から、2020 年 7 月中旬まであまり大きな変動は見られなく停滞していたが、7 月末に上昇し始め 100 万を超えていることが見てとれる。8 月中旬には、2020 年最高額である 130 万円に達した。騰落に関しては、価格が上

²<https://coinmarketcap.com>

昇している日は 65 日、価格が下降している日は 49 日となっている。



図 3: ビットコイン価格の推移 (単位: 円)

ツイートのアカウントに関する情報は、ユーザー名、投稿日時、ツイート、いいね数、RT 数、フォロワー数、フォロワー数の 7 つの変数で構成されている。本研究では、投稿日時、ツイート、いいね数、RT 数、フォロワー数のみを用いる。

説明変数として扱うニュースとツイートのデータは Google Natural Language API を使って感情分析を行い、その出力である感情スコアを算出する。Google Natural Language API は機械学習で構築された強力な事前トレーニング済みモデルで、これを用いるとテキストの構造・感情を明らかにすることが可能である。感情スコアは、-1 から 1 までの値で算出される。-1 に近いほどネガティブで、1 に近いほどポジティブな感情を表す。算出した感情スコアは、次節で述べるように、ツイート情報で重み付けを行った上で、日毎に平均を求め、それらを説明変数として用いる。ニュースの感情スコアについても、次節で述べるように、その日のニュース数で重み付けを行った後に説明変数として用いる。

Google トレンドのデータは、「ビットコイン」の検索数が 0 から 100 に正規化された値をそのまま説明変数として用いる。

2.2 感情スコアの重み付け

先行研究では、1 日の全ニュース記事、全ツイートの感情スコアの平均をその日のニュース、ツイートの感情スコアとして説明変数に用いていた。本研究では、ツイートの感情スコアに関しては、インフルエンサーの影響を考慮するために、いいね数・RT 数・フォロワー数で重み付けを行う。いいね数・RT 数・フォロワー数はそれぞれ 0 以上 1 以下の値をとるように正規化する。重み付けの方法には以下の 2 パターンを考える。

$$\begin{aligned} & \text{ツイートの重み付き感情スコア 1} \\ & = \text{ツイートの感情スコア} \\ & \quad \times (\text{RT 数} + 1) \\ & \quad \times (\text{いいね数} + 1) \end{aligned}$$

$$\times (\text{フォロワー数} + 1) \quad (1)$$

ツイートの重み付き感情スコア 2

$$\begin{aligned} & = \text{ツイートの感情スコア} \\ & \quad \times (\text{RT 数} + \text{いいね数}) \\ & \quad \times (\text{フォロワー数} + 1) \end{aligned} \quad (2)$$

1 日分の全ツイートに対して重み付き感情スコアを算出し、その平均値を、その日のツイートの重み付き感情スコアとする。

ニュース記事についても、その日のニュース数も投資家心理に影響すると考え、感情スコアをニュース数で重み付けしたものを説明変数に用いることを考えた。

ニュースの重み付き感情スコア

$$= \text{ニュースの感情スコア} \times \text{ニュース数} \quad (3)$$

2.3 LSTM ネットワークを用いた騰落予測モデル

本稿では、過去 6 日分の価格と説明変数のデータを用いて、翌日のビットコイン価格の騰落を予測するモデルを構築する。目的変数は価格が 1% 以上の上昇なら +1, 0~1% の上昇なら +0, 0~1% の下降なら -0, 1% 以上の下降なら -1 とラベル化した価格の騰落とする。本稿で提案するモデルの説明変数は、過去 6 日分の価格、ニュース・ツイートの重み付き感情スコア、Google トレンドのデータであるが、ここでは、提案モデルの有用性を示すために、これらの一部を説明変数として用いたモデルと予測精度の比較を行う。こうしたモデルの中には、先行研究で用いられたモデルも含まれる。

2020 年 6 月 26 日から 9 月 25 日までの 92 日間のデータを訓練データ、9 月 26 日から 10 月 17 日までの 22 日間のデータをテストデータとし、活性化関数に softmax 関数、隠れ層数を 64 層、損失関数に交差エントロピー誤差を適用した LSTM ニューラルネットワークによってモデルを構築した。本稿で使用した深層学習のモデル構築には python の機械学習ライブラリである TensorFlow を用いた。

ここでは、22 日間のテストデータに対する騰落の正解率を騰落予測精度とする。また、価格変動率に関わらず上昇・下降のみの正解率を単純騰落予測精度と呼ぶことにする。

Kinderis et al.[10] では、ニュース記事の感情スコアとツイートの感情スコアの他に、説明変数として S&P500 の株価、イリジウムの価格、パラジウムの価格、アルミニウムの価格、コバルトの価格、Length Lumber Futures 社の株価を用いていたが、これらの変数は本研究のデータ期間では予測精度を向上させなかったため、本稿で

は、これらの変数を用いないモデルによる予測結果のみを示す。また、多層パーセプトロンによるモデルを構築も行ったが、LSTM ニューラルネットワークを用いた方が高精度だったため、本稿では LSTM ニューラルネットワークを用いた予測結果のみを示す。

3 騰落予測結果

3.1 予測結果

本節では、6 パターンの説明変数の組に対して学習した LSTM ニューラルネットワークで予測を行った結果を示す。以下では、各モデルの定義を順に述べ、図 4 から図 9 で、予測結果の混同行列を示す。混同行列の図の縦軸は価格変動のラベル、横軸は予測値を表し、色の濃さは度数を表す。

モデル 1 はビットコインの価格データのみを説明変数として用いたもので、22 日分のテストデータに対する騰落予測精度は 23 %、単純騰落予測精度は 50 % という結果であった。図 4 から、どのラベルも予測精度が高くないことが見て取れる。

モデル 2 は価格データに加えて Kinderis et al.[10] でも用いられていたニュースとツイートの重みなしの感情スコアを説明変数として組み込んだもので、騰落予測精度が 27 %、単純騰落予測精度は 55 % となった。価格データだけで構築したモデル 1 と比較すると、若干予測

精度が向上しているが、図 5 を見てもわかるように、モデル 1 と同様に高い精度で予測できているラベルはないことが見てとれる。

モデル 3 は、モデル 2 の価格データ、ニュース・ツイートの感情スコアに加えて Google トレンドのデータを説明変数として組み込んだもので、騰落予測精度が 32 %、単純騰落予測精度は 64 % となった。モデル 2 に Google トレンドのデータを説明変数に加えることで、騰落予測精度が 5 ポイント、単純騰落予測精度は 9 ポイント向上している。図 6 から、0~1 % の価格上昇と 1 % 以上の価格上昇ともに 50 % の確率で予測できていることがわかる。

モデル 4 は価格データ、ニュースの感情スコア、(1) 式のツイートの重み付き感情スコア 1、Google トレンドのデータを説明変数として組み込んだもので、騰落予測精度が 41 %、単純騰落予測精度は 73 % となった。ツイートの感情スコアにいいねの数・RT 数・フォロワー数で重み付けすることで、モデル 3 から騰落予測精度が 9 ポイント、単純騰落予測は 9 ポイント向上している。図 7 から、1 % 以上の価格上昇は 83 %、価格上昇は 100 % の精度で予測できていることがわかる。この結果は、インフルエンサーの影響を考慮に入れることで、予測精度が向上することを示唆している。

モデル 5 は、モデル 4 のニュースの感情スコアを、(3) の重み付き感情スコアで置き換えたものである。このモデルは、騰落予測精度が 41 %、単純騰落予測精度は




図 4: モデル 1 の予測結果




図 6: モデル 3 の予測結果




図 5: モデル 2 の予測結果




図 7: モデル 4 の予測結果




図 8: モデル 5 の予測結果




図 9: モデル 6 の予測結果

82%となった。ニュースの感情スコアをニュース数で重み付けすることで、モデル 3 から騰落予測精度が 9 ポイント、単純騰落予測は 18 ポイント向上した。図 8 から、1%以上の価格上昇は 67%、価格上昇は 92%、価格下降は 60%の精度で予測できていることがわかる。

モデル 6 は、モデル 5 のツイートの重み付き感情スコアを (2) 式の重み付き感情スコアで置き換えたもので、騰落予測精度が 50%、単純騰落予測精度は 82%となった。ツイートの感情スコアにいいねの数と RT 数の和とフォロワー数の積で重み付けすることで、モデル 3 から騰落予測精度が 18 ポイント、単純騰落予測は 18 ポイント向上している。図 9 から、0~1%の価格上昇は 67%、価格上昇は 100%、価格下降は 60%の精度で予測できていることがわかる。モデル 6 が騰落予測精度、単純騰落予測精度ともに最も精度の高いモデルとなった。

3.2 考察

説明変数としてニュースの感情スコアとツイートの感情スコアを組み込んだ Kinderis et al.[10] のモデルは、価格のみのモデルよりも騰落予測精度が 4 ポイント、単純騰落予測精度は 5 ポイント向上するという結果になり、先行研究と同様に精度が向上した。このモデルに Googleトレンドのデータを加えることによってさらに騰落予測精度が 5 ポイント、単純騰落予測精度は 9 ポイント向上するという結果になった。この結果

は、ビットコインの騰落予測における Googleトレンドデータの有用性を示していると言える。ニュースの感情スコアとツイートの感情スコアで投資家の感情を捉えようと考えられる。一方、Googleトレンドでの検索数は投資家のビットコインに対する興味・関心の量を表すと考えられるため、ビットコインの価格が上昇したときだけでなく、価格が下降したときにも増加する。つまり、Googleトレンドのデータは、投資家の感情の強さを捉えようと考えられる。Googleトレンドのデータを用いることで、より正確に人々の感情を捉えることが可能になり、ビットコインの騰落予測精度が向上したと考えられる。

また、Googleトレンドデータに加え、重み付けしたニュース・ツイート感情スコアを組み込んだモデルは、より精度の高いものとなり、重み付けなしのニュース・ツイートの感情スコア、Googleトレンドのデータを組み込んだモデルより、騰落予測精度が 9 ポイント、単純騰落予測精度は 18 ポイント向上するという結果になった。これは、仮説でもあったインフルエンサーの影響が大きいことと、数で重み付けすることでより正確に投資家の感情の強さを捉えられているためであると考えられる。このことから、ツイートの感情スコアをいいねの数・RT数・フォロワー数で重み付けすることの有用性を示すことができたと言える。

ツイートの感情スコアも (1) 式、(2) 式の 2 パターン考えたが、(2) 式の重みの方が騰落予測精度が 9 ポイント向上するという結果になった。一般に、インフルエンサーとはフォロワー数が多い人のことを指す。しかし、人々の感情に影響を与えるという点においては、フォロワー数だけでなく、エンゲージメント率も重要となってくる。エンゲージメント率は以下の式で定義される。

エンゲージメント率

$$= (\text{クリック数} + \text{RT 数} + \text{フォロワー数} + \text{返信数} + \text{いいね数}) / \text{インプレッション} \times 100.$$

Twitter API では RT 数・いいねの数しか収集することができないため、本研究では RT 数といいねの数の和をそのツイートのエンゲージメントと定義する。この重みは、感情スコアにインフルエンサーを表すフォロワー数を掛け、さらにエンゲージメントを表す RT 数といいねの数の和を掛け合わせることによって、インフルエンサーによる拡散力に加えて、インフルエンサーのツイートに対する人々の反応をエンゲージメントとして表現したものと解釈できる。結果として、従来法に比べ精度が飛躍的に向上している点は興味深い。また、日本ではビットコインに関する詐欺アカウントが多く、そのようなアカウントはフォロワーを買っていて、本研究ではインフルエンサーとしての重み付けがされるが、それらはエンゲージメントが極めて低いため、(2) 式の

重みは悪質なツイートを除去するのにも役立つとも考えられる。

4 おわりに

本稿では, Kinderis et al.[10] で扱われていた説明変数で構築したモデルのツイートの感情スコアに, いいね数・被リツイート数・フォロワー数で重み付けを行い, さらに Google トレンドのデータを説明変数に加えることで予測精度が向上するという結果を示した. この結果は, ツイートの感情スコアへの重み付けと Google トレンドのデータがビットコインの騰落予測において有用であることを示していると言える.

本稿では, ビットコインを対象としたが同じような予測手法が用いられている株などの金融商品にも本研究の手法は有用であると考えられる.

謝辞

本研究の一部は本研究は JSPS 科研費 JP17K00061 の助成を受けたものです. また, 本研究を行うにあたり, 同志社大学大学院文化情報学研究所の内藤宏明氏に有益なコメントをいただきました. ここに記して感謝の意を表します.

参考文献

- [1] 和泉潔, 後藤卓, 松井藤五郎 (2010). テキスト情報による金融市場変動の要因分析. *人工知能学会論文誌*, **25**, 3, pp.383–387.
- [2] 和泉潔, 後藤卓, 松井藤五郎 (2011). 経済テキスト情報を用いた長期的な市場動向推定. *情報処理学会論文誌*, **52**, 12, pp.3309–3315.
- [3] 五島圭一, 高橋大志 (2016). ニュースと株価に関する実証分析: ディープラーニングによるニュース記事の評判分析. *証券アナリストジャーナル*, **54**, 3, pp.76–86.
- [4] Rakhi Batra and Sher Muhammad Daudpota (2018). Integrating StockTwits with sentiment analysis for better prediction of stock price movement. In *2018 International Conference on Computing, Mathematics and Engineering Technologies*, pp.1–5.
- [5] Joshi Kalyani, H.N.Bharathi and Rao Jyothi (2014). Stock trend prediction using news sentiment analysis. <https://arxiv.org/ftp/arxiv/papers/1607/1607.01958.pdf>, 2020 年 12 月 2 日閲覧.
- [6] Aparna Nayak, M. M. Manohara Pai and Radhika M. Pai (2016). Prediction Models for Indian Stock Market. *Procedia Computer Science*, **89**, pp.441–449.
- [7] Connor Lamon, Eric Nielsen and Eric Redondo (2017). Cryptocurrency Price Prediction Using News and Social Media Sentiment. *SMU Data Sci. Rev.*, **1**, pp.1–22.
- [8] Vytautas Karalevicius, Niels Degrande and Jochen De Weerd (2018). Using sentiment analysis to predict interday Bitcoin price movements. *Journal of Risk Finance*, **19**, pp.56–75.
- [9] Svitlana Galeshchuk, Oleksandra Vasylychshyn and Andriy Krysovaty (2017). Bitcoin Response to Twitter Sentiments. In *ICT in Education, Research and Industrial Applications*, Springer, pp.160–168.
- [10] Marius Kinderis, Marija Bezbradica and Martin Crane (2018). Bitcoin Currency Fluctuation. In *COMPLEXIS 2018 –3rd International Conference on Complexity, Future Information Systems and Risk*, pp.31–41.
- [11] Ahmed Baig, Benjamin M. Blau and Nasim Sabah (2019). Price clustering and sentiment in bitcoin. *Finance Research Letters*, **29**, pp.111–116.
- [12] Coincheck 「仮想通貨の日本人保有率は? 世界や国別の状況も紹介」, <https://coincheck.com/ja/article/130>, 2020 年 6 月 25 日アクセス.
- [13] Liquid 「ビットコイン (Bitcoin) の取引量は? 国別にみる取引量推移や日本が一位の理由」, <https://blog.liquid.com/ja/knowledge/bitcoin-world-trading-volume/>, 2021 年 2 月 2 日アクセス.