

金融情報学研究会(第25回)

日時 2020 年 10 月 10 日(土)

会場 オンライン

SIG-FiN
JSAI Special Interest Group on
Financial Informatics

人工知能学会
金融情報学研究会

第25回 人工知能学会 金融情報学研究会 (SIG-FIN)

2020 年 10 月 10 日 (土) オンライン

01. Extreme Opinions on Social Media	1
三輪宏太郎(九州大学)	
02. 携帯電話 GPS データに基づく自動車生産量のナウキャストリングと株式投資戦略	9
水門善之(東京大学, 野村證券), 柳井都古杜(野村證券)	
03. コロナショック環境下における AI トレーダーの投資パフォーマンス	13
石原龍太(かんぽ生命保険)	
04. 強化学習を用いたライフサイクル投資	20
上田翼(三井住友 DS アセットマネジメント)	
05. 高頻度取引は金融危機時に市場に悪影響を与えるのか? ~人工市場による一考察~	24
星野真広, 山本浩平(神奈川工科大学), 水田孝信(スパークスアセットマネジメント), 八木勲(神奈川工科大学)	
06. 自発的に市場規模が定まる金融取引モデル	29
片平啓(筑波大学), 陳昱(東京大学), 秋山英三(筑波大学)	
07. タグに基づくデータ拡張と因果文抽出を用いた市況コメント生成の試み	34
坂地泰紀(東京大学), 近藤洋平(大和アセットマネジメント), 和泉潔(東京大学), 長尾慎太郎(大和アセットマネジメント), 加藤惇雄(大和総研)	
08. 債券市場における金融極性辞書の自動構築	38
今井康太, 酒井浩之, 高野海斗(成蹊大学), 北島良三(東京工芸大学), 末廣徹, 稲垣真太郎, 木村柚里(みずほ証券)	
09. 有価証券報告書からのリスク文抽出の試み	44
藤井元雅(東京理科大学), 坂地泰紀, 佐々木一(東京大学), 増山繁(東京理科大学)	
10. 経済データを用いた政府の景気基調判断文の生成とバイアスの検証	49
末廣徹, 木村柚里, 稲垣真太郎(みずほ証券)	
11. 解釈性を持つマクロファクター構成手法	54
野間修平, 中川慧, 伊藤彰朗(野村アセットマネジメント)	
12. 評価関数の可視化による株価予測モデルの汎用性評価	62
坂下好希(東京大学), 瀬之口潤輔(東京工科大学)	

13. t 過程ボラティリティ変動モデル	70
濃野歩(東京大学), 内山祐介(MAZIN), 中川慧(野村アセットマネジメント)	
14. Adaptive Elastic Dynamic Mode Decomposition を用いたモメンタム戦略の改良	76
内山祐介(MAZIN), 中川慧(野村アセットマネジメント)	
15. 人工知能は相場操縦という不正な取引を勝手に行うか?	82
-遺伝的アルゴリズムが人工市場シミュレーションで学習する場合-	
水田孝信(スパークスアセットマネジメント)	
16. 多変量時系列データを用いた分散型強化学習による低リスク行動の学習	89
佐藤葉介, 張建偉 (岩手大学)	
17. Estimation of agent-based models using Bayesian deep learning approach of BayesFlow	95
塩野剛志(クレディ・スイス証券)	

Extreme Opinions on Social Media

三輪 宏太郎¹

KOTARO MIWA¹

¹九州大学 経済学研究院

¹Kyushu University, Faculty of Economics

Abstract: In this study, we analyze the information value of extreme opinions on Twitter that are identified by the most positive and negative Twitter sentiments for each firm. We find that these extreme opinions predict stock returns without subsequent reversals. In addition, they contain incremental information regarding firm fundamentals that are identified by subsequent revisions in analysts' earnings forecasts and target prices. Finally, we find that the return predictability is attributed to the fundamental information contained in the extreme tweets. Our analysis sheds light on the role of extreme opinions on social media.

1. Introduction

An increasing number of studies analyzes the extent to which stock prices incorporate not only quantitative information but also qualitative information, as there are compelling theoretical and empirical reasons to do so. Theoretically, firm valuations should incorporate investors' information sets, which include quantitative and qualitative information. Empirically, substantial stock returns do not seem to correspond to quantitative information (Shiller, 1981; Roll, 1988), suggesting that qualitative information may help explain stock returns.

Accordingly, financial studies have been performing textual analyses on a wide variety of texts. First, studies have focused on texts written by professionals, including corporate disclosures (e.g., Henry, 2008; Li, 2010; Loughran and McDonald, 2011; Rogers et al., 2011; Price et al., 2012; Ferris et al., 2013; Jegadeesh and Wu, 2013; Arslan-Ayaydin et al., 2016) and media articles (e.g., Tetlock, 2007; Tetlock et al., 2008; Engelberg et al., 2012; Garcia, 2012).

Recently, studies have focused on social media. The importance of social media in financial markets has increased substantially over the past decade. However, despite their increasing importance, it is unclear whether textual opinions on social media have any investment value. Bollen et al. (2011) show that aggregated Twitter sentiments predict future stock returns. However, Antweiler and Frank (2004), Das and Chen (2007), and Sprenger et al. (2014) suggest that social media activities are not significantly related to future returns.

Although social media could be an essential communication tool between investors and firms, it is also true that most of the tweets merely reflect the opinions of non-professional and uninformed social media users.

Their tweets may be driven by rumors and contain significant noise. The existence of low-quality and uninformed tweets could result in mixed findings regarding the informational value of aggregated (consensus) opinions on social media, even if there are some informative tweets. Conversely, the mixed results do not deny the possibility that there are informative opinions on social media.

Thus, in this study, we analyze the existence of informative opinions on social media by focusing on opinions that diverge from the consensus. The reason why we focus on such extreme opinions is that informed users' opinions could significantly differ from the opinions of many uninformed users. In other words, an informed user's opinions could be extreme relative to the consensus. Thus, extreme opinions could have more informational value than other (non-extreme) opinions. We identify these opinions by utilizing the textual sentiment of each tweet. Specifically, we identify the extreme opinions regarding each firm on a daily basis by the most positive and negative Twitter sentiment scores for the corresponding firm released over a 24-hour period.

The extremeness of a tweet's sentiment could be attributed to measurement errors. Therefore, we utilize a highly sophisticated Twitter sentiment indicator whose methodology is carefully examined—Bloomberg's social sentiment analytics. The sentiments are calculated using tweets from Twitter and StockTwits regarding a given firm. Bloomberg identifies tweets about a given firm and then determines the positiveness or negativeness of the tweet (story-level sentiment) and its confidence score by utilizing supervised machine learning. Sentiment scores are calculated based on the confidence-weighted average of the story-level sentiments at fixed intervals (e.g., two

minutes).

In addition to the sophisticated methodology, there are advantages to using Bloomberg's social sentiment analytics. First, because the sentiment indicator information has been released regularly for more than five years, using Bloomberg's analytics makes our study replicable and transparent. Second, Bloomberg calculates firm-level news sentiments. The posts on social media could merely rehash what was reported in news media. We can address this possibility by controlling for news sentiments when testing the predictive ability of Twitter sentiments. In other words, we can examine whether Twitter sentiments provide incremental information relative to that contained in news media.

Our first main result is that the extreme opinions that are identified by the most positive and negative Twitter sentiments for each firm have predictive power for subsequent stock returns beyond the consensus opinions, which are identified by the average Twitter sentiments. This predictability is not subsumed by traditional return predictors and news sentiments.

Further, stock returns associated with extreme opinions are not reversed in the subsequent periods. This result indicates that extreme opinions have a permanent impact on stock prices, supporting the view that extreme tweets contain incremental information that is not incorporated in stock prices. On the other hand, returns associated with consensus opinions are significantly reversed. This casts doubt on the informational value of consensus opinions and suggests that such opinions contain no relevant information but only temporarily shift the demand for a stock.

In a further analysis, we examine possible sources of cross-sectional return predictability with extreme opinions. To this end, we examine the informational role of extreme opinions by looking at two types of cross-sectional information flow indicators regarding firm fundamentals: changes in analysts' target prices and revisions in their quarterly earnings forecasts. We first examine whether extreme opinions predict subsequent changes in target prices and earnings forecasts. We then examine whether the cross-sectional return predictability with extreme opinions is explained by the fundamental information identified by the two indicators.

We find that the extreme opinions predict subsequent changes in target prices and earnings forecasts, whereas consensus opinions do not have any predictive power. The results support the view that extreme opinions, rather than consensus opinions, contain incremental information regarding firm fundamentals. Further, we find that the return predictability of tweets is mediated by the

predictive power for the target prices and earnings forecasts. Together, these findings suggest that extreme opinions posted on social media (especially negative ones) contain new information about firm fundamentals, and this information drives the predictive power for cross-sectional returns.

Existing literature on social media focuses on consensus opinions. In contrast to these studies, we focus on extreme opinions on social media and provide robust evidence that they have significant informational value regarding stock valuation and firm fundamentals.

2. Hypotheses Development

2.1. Return Predictability

As discussed in Section 1, although most of the tweets are not informative, there could be a limited number of informative tweets, and those opinions could significantly differ from the consensus opinion. Thus, extreme tweets, which diverge from consensus opinions, could contain additional information regarding stock valuation. As such, the following hypothesis is proposed: H1: Extreme tweets have incremental predictive power for subsequent returns.

However, even if H1 is supported, we cannot conclude that the extreme tweets contain incremental information regarding stock valuation. Stock prices could react to the tweets even when investors respond inappropriately to the incorrect or biased views of extreme tweets. However, in this case, returns would subsequently reverse. In contrast, if the extreme tweets contain incremental information, a price correction would not occur. This argument leads to the following hypothesis:

H2: Abnormal returns associated with extreme tweets are not reversed.

2.2. Fundamental Information

Because information flow regarding corporate fundamentals has a permanent price impact, extreme tweets, which also have a permanent price impact, likely contain relevant information about corporate fundamentals. Thus, the following hypothesis is given: H3: Extreme tweets contain relevant information about firm fundamentals.

When the fundamental information contained in the extreme tweets is disclosed, the stock price reacts significantly to (incorporate) it. Thus, the return predictability with extreme tweets can be attributed to such information about corporate fundamentals. These intuitions lead to the following hypothesis:

H4: Return predictability with extreme tweets is attributed to fundamental information contained in the extreme tweets.

3 Extreme Opinion Measures

3.1. Twitter Opinion Measure

To identify the opinion of each tweet, we utilize the text-based sentiment of tweets for each firm. Specifically, we utilize Bloomberg's firm-level Twitter sentiment measures to identify the positive and negative opinions for each firm. Bloomberg uses supervised statistical machine-learning techniques to construct a firm-level Twitter sentiment index. Bloomberg's social sentiment classification engines are trained to mimic a human expert in processing textual information. Once the model is trained, when new tweets are tagged with company tickers, the model automatically assigns a probability of being positive, negative, or neutral to each tweet.

Bloomberg calculates the story-level sentiment (undisclosed data) and then provides the firm-level sentiment. The story-level sentiment is generated in real-time upon the arrival of tweets. It consists of two parts: score and confidence. The sentiment score is a categorical value, for example, 1, -1, and 0, which indicates a positive, negative, and neutral sentiment, respectively. Confidence is a numerical value ranging from 0% to 100%, which can be interpreted as the probability of being positive, negative, or neutral. Thus, the story-level sentiment, which is defined by multiplying the story-level sentiment score by the corresponding confidence score, varies from -1 to 1.

The firm-level average sentiment score (the average sentiment score for each firm), denoted as $Twitter_{i,t}^{Mean}$, is the average of the story-level Twitter sentiment over a 24-hour period from 9:20 a.m. on the previous day ($t-1$) to 9:20 a.m. on the current day (t). Bloomberg calculates the average of the story-level sentiment score every two minutes and provides the highest and lowest two-minute sentiment scores over the 24-hour period on a daily basis. Bloomberg provides these scores for all U.S. stocks each morning about 10 minutes before the U.S. stock market opens. Because the highest and lowest sentiment scores are likely to capture the most positive and negative opinions for each day, we utilize these scores as opinions of the extreme tweets.

3.2. Opinions of Extreme Tweets

For an opinion of the extreme tweets for firm i on day t , denoted as $Twitter_{i,t}^{Extreme}$, we calculate mid-range scores, that is, the arithmetic mean of the highest and lowest sentiment scores as:

$$Twitter_{i,t}^{Extreme} = \frac{Twitter_{i,t}^{Highest} + Twitter_{i,t}^{Lowest}}{2}$$

where $Twitter_{i,t}^{Highest}$ and $Twitter_{i,t}^{Lowest}$ are the highest and lowest two-minute sentiment scores for firm i over a 24-hour period from 9:20 a.m. on the previous day ($t-1$) to 9:20 a.m. on the current day (t)¹. Then, we examine whether $Twitter_{i,t}^{Extreme}$ has incremental predictive power for subsequent cross-sectional returns beyond $Twitter_{i,t}^{Mean}$.

The mid-range scores $Twitter_{i,t}^{Extreme}$ based on the highest and lowest sentiment scores mainly reflect the opinions of the extreme tweets, whereas the average sentiment $Twitter_{i,t}^{Mean}$ reflects not only the opinions of these extreme tweets but also those of a considerable number of non-extreme tweets. Thus, the mid-range scores reflect more precisely the opinions of extreme tweets than the average scores.

First, let us suppose that the informational value is no higher for extreme tweets than for others (tweets are equally informed). Specifically, suppose that each tweet's sentiment follows $\theta + \epsilon$, where θ is the information set regarding the firm valuation and ϵ is an error term. In this case, because the mid-range measures $Twitter_{i,t}^{Extreme}$ are more naïve (less efficient) estimators for θ than the average measures $Twitter_{i,t}^{Mean}$, the mid-range measures should have no predictive power for subsequent returns after controlling for $Twitter_{i,t}^{Mean}$.

Next, suppose that the extreme tweets contain an additional information set $\hat{\theta}$ (either the extreme positive or negative tweets reflect an incremental information set $\hat{\theta}$ regarding firm valuation). The mid-range measure, which is highly dependent on the opinions of these extreme tweets, is more likely to capture information set $\hat{\theta}$ (more efficient estimator for $\hat{\theta}$) than the average measure. Thus, the mid-range measure $Twitter_{i,t}^{Extreme}$ could have additional predictive power for stock returns even after controlling for $Twitter_{i,t}^{Mean}$.

4. Return Predictability with Extreme Tweets

4.1. Methodology

To test H1, we investigate the predictive power of extreme tweets on stock returns. Specifically, we use daily cross-sectional regressions similar to those in Fama and MacBeth (1973). We first run cross-sectional regressions for each day, and then report the time-series averages of the daily coefficient estimates and the corresponding t-statistics based on the Newey-West standard errors.

and lowest two-minute sentiments as $Twitter_{i,t}^{Highest}$ and $Twitter_{i,t}^{Lowest}$, respectively.

¹ 720 two-minute sentiment scores are calculated at two-minutes interval over a 24-hour period from 9:20 a.m. on the previous day $t-1$ to 9:20 a.m. on the current day t . We utilize the highest

As previously mentioned, the Twitter sentiment is released in the morning right before the stock market opens. Thus, to analyze the return predictability with the Twitter sentiment, we analyze the predictive power of $Twitter_{i,t-1}^{Extreme}$ for the open-to-open return $Ret_{i,t}$ from stock i 's opening price on day $t-1$ to the opening price on day t . We also analyze the predictive power for the risk-adjusted open-to-open returns, defined as the residuals of the Fama-French-Carhart four-factor model. This approach also theoretically allows one to trade at the 9:30 a.m. market opening after observing the Twitter scores for the previous day released at 9:20 a.m. The regression specification is as follows:

$$Ret_{i,t} = \alpha + \beta_1 Twitter_{i,t-1}^{Extreme} + (Controls) + \varepsilon_{i,t} \quad (1)$$

$$Ret_{i,t} = \alpha + \beta_1 Twitter_{i,t-1}^{Extreme} + \beta_2 Twitter_{i,t-1}^{Mean} + (Controls) + \varepsilon_{i,t} \quad (2)$$

The coefficient of $Twitter_{i,t-1}^{Extreme}$ is our main parameter of interest. Following the study of Gu and Kurov (2018), in addition to $Twitter_{i,t-1}^{Mean}$, we control for return momentum, volatility, abnormal trading volume, and news sentiment.

Five lags of daily (open-to-open) returns ($Ret_{i,t-k}$: $k=1,2,\dots,5$) are included because return autocorrelation associated with a contemporaneous correlation of returns and sentiment can generate spurious evidence of lead-lag relations (e.g., Chordia and Swaminathan, 2000; Rapach et al., 2013). Hence, the regression controls include firm i 's five lags of daily (open-to-open) returns.

Following the study of Tetlock (2011), the regression also controls for volatility. In particular, we control for five lags of daily return volatility ($Volatility_{i,t-k}$: $k=1,2,\dots,5$). We use Rogers and Satchell's (1991) extreme value volatility estimator to measure daily volatility. The estimator is computed as follows:

$$Volatility_{i,t} = (p_{i,t}^{Highest} - p_{i,t}^{Close})(p_{i,t}^{Highest} - p_{i,t}^{Open}) + (p_{i,t}^{Lowest} - p_{i,t}^{Close})(p_{i,t}^{Lowest} - p_{i,t}^{Open})$$

where $p_{i,t}^{Highest}$, $p_{i,t}^{Lowest}$, $p_{i,t}^{Open}$, and $p_{i,t}^{Close}$ are the log-transformed highest, lowest, opening, and closing prices of stock i on day t , respectively.

Five lags of the daily abnormal trading volume ($Volume_{i,t-k}$: $k=1,2,\dots,5$) are included to control for the high-volume return premium of Gervais et al. (2001). We use the abnormal trading volume to make the volume comparable across firms. Specifically, following the methodology of Gervais et al.'s (2001) study, we compute the abnormal trading volume ($Volume_{i,t}$) by dividing the trading volume for stock i on day t by the mean volume

during the preceding 49-day period (from $t-49$ to $t-1$). Both abnormal volume and volatility are expressed as percentage points.

The news sentiment on day $t-1$, denoted as $News_{i,t-1}$, is added as an additional regressor because tweets could simply refer to firm-specific news. By adding the news sentiment, we can evaluate the incremental informational value of extreme tweets ($Twitter_{i,t-1}^{Extreme}$) beyond firm-specific news. If fundamental information diffuses from traditional media to social media, we should expect the predictive power of tweets for stock returns to disappear after controlling for the news sentiment. We obtain the firm-specific news sentiment from Bloomberg. It is measured by following the same procedure as that used to calculate the average Twitter sentiment ($Twitter_{i,t}^{Mean}$) and is based on all news published by Bloomberg. $News_{i,t}$ is the average of the story-level news sentiment over a 24-hour period from 9:20 a.m. on the previous day ($t-1$) to 9:20 a.m. on the current day (t). The value of the news sentiment ranges from +1 to -1 and is released before the market opens (at 9:20 am).

Finally, to control for the return predictability stemming from firm characteristics, we include the firm size, measured as the logarithm of the market value of equity ($Size_{i,t-1}$), book-to-market ratio ($Value_{i,t-1}$), and 12-month returns except for the most recent month ($Momentum_{i,t-1}$)².

To test H2, which posits that abnormal returns with extreme tweets are not reversed, five lags of the extreme tweets' sentiments ($Twitter_{i,t-k}^{Extreme}$: $k=1, 2, \dots, 5$) and the average sentiment ($Twitter_{i,t-k}^{Mean}$: $k=1, 2, \dots, 5$) are included in the regression model as:

$$Ret_{i,t} = \alpha + \sum_{k=1}^5 \beta_{1,k} Twitter_{i,t-k}^{Extreme} + \sum_{k=1}^5 \beta_{2,k} Twitter_{i,t-k}^{Mean} + (Controls) + \varepsilon_{i,t} \quad (3)$$

In terms of control variables, we include lagged news sentiment measures ($News_{i,t-k}$: $k=2, 3, 4$, and 5). Other control variables are the same as in Equation (2). As discussed in Section 2.2.1, if the extreme tweet contains useful fundamental information about stocks, its effect on returns should be permanent. On the other hand, if the opinions of the extreme tweet simply reflect the incorrect or biased opinions of uninformed traders, the impact of the tweets on stock returns should be reversed over the next few trading days. To test whether returns associated with $Twitter_{i,t-1}^{Extreme}$ and $Twitter_{i,t-1}^{Mean}$ are temporary or permanent, we examine whether the coefficients of the lagged sentiment measures ($Twitter_{i,t-k}^{Extreme}$: $i=2, 3, 4$, and 5) are significantly negative.

² These variables are not included in the regression model when we analyze the predictive power for the risk-adjusted returns

based on the Fama-French (1993) and Carhart (1997) four-factor models.

4.2. Result

We run regressions for both raw and risk-adjusted returns. Table 1 shows that not only the average sentiment ($Twitter_{i,t-1}^{Mean}$) but also the extreme tweets' sentiments ($Twitter_{i,t-1}^{Extreme}$) have significant predictive power for subsequent returns ($Ret_{i,t}$). Even after controlling for $Twitter_{i,t-1}^{Mean}$, the coefficient of $Twitter_{i,t-1}^{Extreme}$ is still significantly positive at the 1% level. Opinions of extreme tweets have incremental predictive power for subsequent returns beyond the consensus opinions. These results support H1.

Table 1 Return Predictability with Extreme Tweets

a) Raw Returns		
	(1)	(2)
$Twitter_{i,t-1}^{Excess}$	0.00200 *** (6.00)	0.00112 *** (2.89)
$Twitter_{i,t-1}^{Mean}$		0.00081 *** (4.27)
Controls	Yes	Yes
R2	9.1%	9.1%
b) Risk-adjusted Returns		
	(1)	(2)
$Twitter_{i,t-1}^{Excess}$	0.00204 *** (5.46)	0.00117 *** (2.83)
$Twitter_{i,t-1}^{Mean}$		0.00082 *** (3.95)
Controls	Yes	Yes
R2	7.6%	7.6%

Table 2 shows the results of the predictive power of the five lags of the extreme tweets' measures. The coefficient of $Twitter_{i,t-1}^{Extreme}$ remains significantly positive. Further, the coefficient estimates on the four lags of the measures (lags of the extreme tweets' measures except for the most recent one; $Twitter_{i,t-k}^{Extreme}$: $i=2,3,4$, and 5) are not significantly negative. Thus, it suggests that the abnormal returns associated with $Twitter_{i,t-1}^{Extreme}$ are not reversed in a subsequent period, supporting H2. These findings are consistent with the notion that opinions of extreme tweets have a permanent price impact on stock prices and thus contain some information regarding stock valuation.

On the other hand, the results reveal that the coefficient of $Twitter_{i,t-2}^{Mean}$ is significantly negative, indicating that the abnormal return associated with the average sentiment $Twitter_{i,t-1}^{Mean}$ is significantly reversed on a subsequent day. This result casts doubt on the notion that the average sentiment, that is, the consensus opinion

of tweets, contains incremental information regarding stock valuation, which is consistent with the mixed prior studies' findings regarding the informational value of consensus opinions on Twitter.

Table 2 Return Predictability with Lagged Tweets

	Raw	Risk-adjusted
$Twitter_{i,t-1}^{Excess}$	0.00164 *** (3.88)	0.00171 *** (4.21)
$Twitter_{i,t-2}^{Excess}$	-0.00040 (0.96)	-0.00039 (0.83)
$Twitter_{i,t-3}^{Excess}$	-0.00014 (0.36)	-0.00008 (0.18)
$Twitter_{i,t-4}^{Excess}$	0.00003 (0.09)	-0.00037 (0.90)
$Twitter_{i,t-5}^{Excess}$	0.00009 (0.28)	-0.00014 (0.36)
$Twitter_{i,t-1}^{Mean}$	0.00082 *** (4.24)	0.00086 *** (3.89)
$Twitter_{i,t-2}^{Mean}$	-0.00070 *** (2.80)	-0.00074 *** (2.94)
$Twitter_{i,t-3}^{Mean}$	-0.00018 (0.95)	-0.00019 (0.77)
$Twitter_{i,t-4}^{Mean}$	-0.00033 (1.25)	-0.00032 (1.25)
$Twitter_{i,t-5}^{Mean}$	0.00028 (1.24)	0.00022 (0.85)
Controls	Yes	Yes
R2	9.1%	7.8%

5. Predictive Power for Fundamentals

5.1. Methodology

The previous section shows that $Twitter_{i,t-1}^{Extreme}$ has predictive power for cross-sectional returns. This section examines the $Twitter_{i,t-1}^{Extreme}$ prediction of the cross-sectional information flow regarding corporate fundamentals. Then, we investigate whether the cross-sectional return predictability associated with $Twitter_{i,t-1}^{Extreme}$ is attributed to the cross-sectional information flow predicted by $Twitter_{i,t-1}^{Extreme}$.

To capture the cross-sectional information flow regarding corporate fundamentals, we utilize revisions in the analysts' earnings forecasts and target prices. Financial analysts continuously research time-varying corporate fundamentals, along with macroeconomic and microeconomic conditions, to update predictions about a company's performance (e.g., earnings). Then, they estimate each stock's fair value (target price) based on its outlook³. Thus, their earnings forecasts and target prices are expected to reflect information regarding corporate fundamentals in a timely manner⁴. Therefore, revisions in

³ Finally, they recommend buying or selling a company's stock based upon the difference between the actual price and the

estimated fair value.

⁴ We do not include stock recommendations as an indicator for

earnings forecasts and target prices are expected to capture the information flow regarding corporate fundamentals. These revisions are suitable for identifying the cross-sectional distribution of new information sets regarding firm fundamentals.

We compute the target price change $\Delta TP_{i,t}$ and earnings revisions $\Delta Earnings_{i,t}$ as

$$\Delta TP_{i,t} = \frac{TP_{i,t}}{TP_{i,t-1}} - 1$$

$$\Delta Earnings_{i,t} = \frac{Earnings_{i,t} - Earnings_{i,t-1}}{Price_{i,t-1}}$$

where $TP_{i,t}$ is the average target price for firm i at t , $Earnings_{i,t}$ is the average earnings forecast of firm i for the most recent quarter at t , and $Price_{i,t}$ is the stock price of firm i at t .

To test H3, which posits that extreme tweets contain some relevant information about corporate fundamentals, we regress these two indicators as:

$$y_{i,t} = \alpha + \beta_1 Twitter_{i,t-1}^{Extreme} + \beta_2 Twitter_{i,t-1}^{Mean} + \beta_3 \Delta TP_{i,t-1} + \beta_4 \Delta Earnings_{i,t-1} + (Controls) + \varepsilon_{i,t} \quad (4)$$

where $y_{i,t}$ is either $\Delta TP_{i,t}$ or $\Delta Earnings_{i,t}$. We additionally include $\Delta TP_{i,t-1}$ and $\Delta Earnings_{i,t-1}$ as control variables to account for the gradual update of analysts' target prices and earnings forecasts. Other control variables are the same as in Equation (2).

Next, we analyze whether the return predictability with $Twitter_{i,t-1}^{Extreme}$ is attributed to the predictive power for $\Delta TP_{i,t}$ and $\Delta Earnings_{i,t}$. To this end, we perform a mediation analysis by running the following regression model:

$$Ret_{i,t} = \alpha + \beta_1 Twitter_{i,t-1}^{Extreme} + \beta_2 Twitter_{i,t-1}^{Mean} + \beta_3 \Delta TP_{i,t} + \beta_4 \Delta Earnings_{i,t} + (Controls) + \varepsilon_{i,t} \quad (5)$$

In regression model (5), $\Delta TP_{i,t}$ and $\Delta Earnings_{i,t}$ are included as control variables for testing the mediation effect. Other control variables are the same as in Equation (2).

We first analyze whether the coefficients of $\Delta TP_{i,t}$ and $\Delta Earnings_{i,t}$ (β_3 and β_4 in Equation (5)) are significantly positive. Then, we examine whether the coefficients of $Twitter_{i,t-1}^{Extreme}$ are significantly reduced by adding $\Delta TP_{i,t}$ and $\Delta Earnings_{i,t}$; in other words, the estimated β_1 in Equation (5) is significantly lower than the estimated β_1 in Equation (2).

5.2. Results

Table 3 shows the regression results of regression model (4) estimated using the Fama-MacBeth approach. The results reveal that $\Delta TP_{i,t}$ and $\Delta Earnings_{i,t}$ are significantly associated with $Twitter_{i,t-1}^{Extreme}$, whereas

the association is much weaker with $Twitter_{i,t-1}^{Mean}$. An upgrade (downgrade) in a firm's target price and earnings forecasts is more likely to occur after Twitter users express extremely positive (negative) views about the firm. This result indicates that the extreme tweets contain incremental information regarding firm fundamentals beyond analysts' earnings forecasts, target prices, and consensus opinions on Twitter, supporting H3.

Table 3 Fundamentals of Extreme Tweets

	Earnings Forecast (x1000)	Target Price (x1000)
$Twitter_{i,t-1}^{Excess}$	0.0271 *** (2.63)	1.1514 *** (7.61)
$Twitter_{i,t-1}^{Mean}$	0.0063 (0.99)	0.2343 ** (2.27)
Controls	Yes	Yes
R2	3.7%	4.7%

Table 4 shows the results of the mediation analysis, that is, regression results of regression model (5) estimated using the Fama-MacBeth approach. The significant positive coefficients of $\Delta TP_{i,t}$ and $\Delta Earnings_{i,t}$ on $Ret_{i,t}$ indicate that revisions in analysts' target prices and earnings forecasts have a significant impact on stock prices. As $Twitter_{i,t-1}^{Extreme}$ predicted $\Delta TP_{i,t}$ and $\Delta Earnings_{i,t}$, the results suggest that the association between $Twitter_{i,t-1}^{Extreme}$ and $Ret_{i,t}$ could be mediated by the predictive power of $Twitter_{i,t-1}^{Extreme}$ for $\Delta TP_{i,t}$ and $\Delta Earnings_{i,t}$. In other words, the extreme tweets contain fundamental information that is subsequently reflected in (disclosed by) analysts' earnings forecasts and target prices, and the return predictability with the extreme tweets could be attributed to the price impact caused by the disclosure of the information.

The magnitude and statistical significance of the coefficient of $Twitter_{i,t-1}^{Extreme}$ are reduced by adding $\Delta TP_{i,t}$ and $\Delta Earnings_{i,t}$ as control variables. As shown in Tables 1 and 4, the coefficient declines significantly (from 0.00112 to 0.00071 when we utilize raw returns and from 0.00117 to 0.00056 when we utilize risk-adjusted returns). Precisely, fundamental information that is subsequently reflected in (disclosed by) analysts' target prices and earnings forecasts explains about 51.6% $((0.00117 - 0.00056) / 0.00117)$ of the predictive power of the extreme tweets for the risk-adjusted return. Further, the coefficient of $Twitter_{i,t-1}^{Extreme}$ is no longer significant after controlling for the mediation effects. Thus, these results suggest that the return predictability with extreme tweets is grounded in the fundamental information

corporate fundamentals because recommendations could be upgraded or downgraded due to stock price changes (even if

corporate fundamentals do not change).

contained in the tweets, supporting H4.

However, a significant decline is not observed for the coefficient of $Twitter_{i,t-1}^{Mean}$, which drops only by approximately 20%, and the coefficients remain statistically significant. The return predictability with a consensus opinion on Twitter is not significantly grounded in information regarding firm fundamentals. This might result in a strong reversal of the abnormal returns associated with consensus opinions on Twitter ($Twitter_{i,t-1}^{Mean}$).

Table 4 Fundamentals of Extreme Tweets

	Raw	Risk-adjusted
$Twitter_{i,t-1}^{Excess}$	0.00071 (1.89)	0.00056 (1.41)
$Twitter_{i,t-1}^{Mean}$	0.00067 *** (3.61)	0.00063 ** (3.13)
$\Delta TP_{i,t}$	0.33292 *** (27.15)	0.31617 *** (28.50)
$\Delta Earnings_{i,t}$	1.79070 *** (4.44)	1.47980 *** (4.00)
Controls	Yes	Yes
R2	14.3%	12.3%

6. Conclusion

In this study, we empirically analyze whether extreme opinions on social media contain incremental information regarding intrinsic firm value beyond the consensus opinions. To this end, we analyze whether the opinions of extreme tweets that are identified by the highest and lowest firm-specific Twitter sentiments have incremental predictive power for subsequent cross-sectional stock returns.

Our empirical analysis reveals that not only the consensus opinions but also the extreme tweets' opinions have predictive power for cross-sectional returns. Furthermore, the abnormal returns associated with the extreme tweets are not significantly reversed, whereas those with consensus opinions are significantly reversed.

These findings support the view that extreme opinions on Twitter contain incremental information regarding firm valuation, but they cast doubt on whether consensus opinions have enough informational value.

In addition, we find that the opinions of extreme tweets predict subsequent revisions in analysts' target prices and earnings forecasts, suggesting that they contain information regarding firm fundamentals. Moreover, the return predictability with the extreme tweets can be explained by their predictive power for firm fundamentals.

In sum, our findings suggest that extreme opinions on Twitter contain incremental information regarding firm fundamentals and valuation. The contributions of our

findings to existing studies can be summarized as follows.

Our study is the first to provide evidence for the informational value of extreme tweets. Because studies only analyze consensus (averaged) opinions on Twitter, it is inconclusive regarding the informational (investment) value of the extreme opinions. We provide evidence by showing their significant predictive power for cross-sectional returns and firm fundamentals.

These results also raise the possibility that there are informative opinions regarding firm valuation on social media. Studies have focused on consensus opinions on social media and show mixed results regarding their informational value. In this study, we provide robust evidence regarding the existence of informed opinions on social media by focusing on extreme tweets.

References

- Antweiler, W., and Frank, M., 2004. Is all that talk just noise? The information content of internet stock message boards. *Journal of Finance*, 59, 1259–1294.
- Arsilan-Ayaydin, O., Boudt, K., and Thewissen, J., 2016. Managers set the tone: Equity incentives and the tone of earnings press releases. *Journal of Banking and Finance*, 72, 132–147.
- Bartov, E., Faurel, L., and Mohanram, P., 2018. Can Twitter help predict firm-level earnings and stock returns? *Accounting Review*, 93(3), 25–57.
- Blankespoor, E., Miller, G. S., and White, H. D., 2014. The role of dissemination in market liquidity: Evidence from firms' use of Twitter TM. *Accounting Review*, 89, 79–112.
- Bollen, J., Mao, H., and Zheng, X., 2011. Twitter mood predicts the stock market. *Journal of Computational Science*, 2, 1–8.
- Carhart, M. M., 1997. On the persistence of mutual fund performance. *Journal of Finance*, 52, 57–82.
- Chordia, T., Swaminathan, B., 2000. Trading volume and cross-autocorrelations in stock returns. *Journal of Finance*, 55, 913–935.
- as, R., and Chen, M., 2007. Yahoo! for Amazon: Sentiment extraction from small talk on the Web. *Management Science*, 53, 1375–1388.
- Engelberg, J., Reed, A., and Ringgenber, M., 2012. How are shorts informed? Short sellers, news, and information processing. *Journal of Financial Economics*, 105(2), 260–278.
- Fama, E. F., and French, R. K., 1993. Common risk factors in the returns of stocks and bonds. *Journal of Financial Economics*, 33, 3–56.
- Fama, E. F., and Macbeth, J. D., 1973. Risk, return, and equilibrium: Empirical tests. *Journal of Political Economy*,

- 81, 607-636.
- Ferris, P., Hao, G., and Liao, M., 2013. The effect of issuer conservatism on IPO pricing and performance. *Review of Finance*, 17(3), 993–1027.
- Garcia, D., 2012. Sentiment during recessions. *Journal of Finance*, 68(3), 1267–1300.
- Gervais, S., Kaniel, R., Mingelgrin, H. D., 2001. The high-volume return premium. *Journal of Finance*, 56, 877-919.
- Gu, C., and Kurov, A., 2018. Informational role of social media: Evidence from Twitter sentiment, Working paper.
- Henry, E., 2008. Are investors influenced by how earnings press releases are written? *Journal of Business Communication*, 45(4), 363–407.
- Jegadeesh, N., and Wu, A., 2013. Word power: A new approach for content analysis. *Journal of Financial Economics*, 110(3), 712–729.
- Kothari, P., Shu, S., and Wysocki, P., 2009. Do managers withhold bad news? *Journal of Accounting Research*, 47, 241–276.
- Li, F., 2010. The information content of forward-looking statements in corporate filings: A naïve Bayesian machine learning algorithm approach. *Journal of Accounting Research*, 48, 1049–1102.
- Loughran, T., and McDonald, B., 2011. When is a liability not a liability? Textual analysis, dictionaries, and 10-Ks. *Journal of Finance*, 66, 35–65.
- Mao, H., Counts, S., and Bollen, J., 2015. Quantifying the effects of online bullishness on international financial markets. Statistics Paper Series 9, European Central Bank.
- Miller, G., 2002. Earnings performance and discretionary disclosure. *Journal of Accounting Research*, 40, 173–204.
- Price, M., Doran, J., Peterson, D., and Bliss, B., 2012. Earnings conference calls and stock returns: The incremental informativeness of textual tone. *Journal of Banking and Finance*, 36(4), 992–1011.
- Rapach, D., Strauss, J., and Zhou, G., 2013. International stock return predictability: What is the role of the United States? *Journal of Finance*, 68, 1633-1662.
- Rogers, L. C. G., and Satchell, S. E., 1991. Estimating variance from high, low and closing prices. *Annals of Applied Probability*, 1, 504-512.
- Rogers, L. C. G., Van Buskirk, A., and Zechman, S., 2011. Disclosure tone and shareholder litigation. *Accounting Review*, 86(6), 2155–2183.
- Roll, R., 1988. R-squared. *Journal of Finance*, 43, 541–566.
- Securities and Exchange Commission (SEC). 2013. SEC says social media OK for company announcements if investors are alerted. Available at <http://www.sec.gov/News/PressRelease/Detail/PressRelease/1365171513574>
- Shiller, R., 1981. Do stock prices move too much to be justified by subsequent changes in dividends? *American Economic Review*, 71, 421–436.
- Sprenger, O., Tumasjan, A., Sandner, G., and Welpe, M., 2014. Tweets and trades: The information content of stock microblogs. *European Financial Management*, 20, 926-957.
- Tetlock, C., 2007. Giving content to investor sentiment: The role of media in the stock market. *Journal of Finance*, 62, 1139–1168.
- Tetlock, C., Saar-Tsechansky, M., and Macskassy, S., 2008. More than words: Quantifying language to measure firms' fundamentals. *Journal of Finance*, 63, 1437–1467.
- Tetlock, C., 2011. All the news that's fit to reprint: do investors react to stale information? *Review of Financial Studies*, 24, 1481-1512.

携帯電話 GPS データに基づく 自動車生産量のナウキャストイングと株式投資戦略

Using mobile phone GPS data to nowcast auto production activity
and draw up an equity investment strategy

水門善之^{1,2,3*} 柳井都古杜^{2,3}

Yoshiyuki Suimon^{1,2,3} Mikoto Yanai^{2,3}

¹ 東京大学大学院工学系研究科システム創成学専攻

¹ Department of Systems Innovations, School of Engineering
The University of Tokyo

² 野村證券株式会社金融経済研究所経済調査部

² Economic Research Department, Financial and Economic Research Center
Nomura Securities Co., Ltd.,

³ 野村證券株式会社金融工学研究センターデータサイエンス部

³ Data Science Department, Financial Engineering and Technology Research Center
Nomura Securities Co., Ltd.,

Abstract: 景気の先行きを考える上で、製造業の生産活動の活況度合いをいち早く把握することは重要である。本研究では、日本における製造業の主要業種である自動車工業の生産量のナウキャストイング手法を提案する。具体的には、携帯電話端末の位置情報（GPS 情報）を用いることで、大手自動車メーカーの工場の敷地内に滞在している人数を時間帯ごとに計測し、そこから得られる情報を基に、自動車工業の生産状況を推計するモデルの構築を行った。これにより、高い速報性を保ちつつ、大手自動車各社の生産量の概ねの推計に成功した。更に本研究では、同情報が示すメーカーごとの生産状況の趨勢に基づく株式投資戦略を構築することで、堅調なパフォーマンスを確認した。このことは、株式市場予測における、携帯電話の位置情報に基づく生産量把握の有効性を示す結果と言えよう。

1. はじめに

昨今、経済分析において、従来の経済統計を補完する形で、様々なデータを活用する流れが進んでいる。これらは、オルタナティブデータと呼ばれ、高頻度の売上データや物流データ、更には経済活動を物理的に観測した画像等のような非構造化データまで多岐に渡る。オルタナティブデータを使用するメリットは、その情報の豊富さに加え、速報性の高さも挙げられる。例えば、速報性に特化した経済動態把握を目的として、クレジットカードの決済データや、小売店での販売時点情報管理 (POS : Point of Sale) データ等、様々な商業用データを統合的に用いて消

費動向をリアルタイムかつ高精度で推計する分析等が行われている[1][2]。更に、人々の行動を捉えた携帯電話端末の位置情報（GPS データ）を用いることで、人々の行動と消費関連のマクロ経済統計の関係性を示した研究も挙げられる[3]。また、消費動向に加えて、景気全般の動向を捉える上では、製造業の生産活動の活況度合いをいち早く把握することは重要である。製造業の生産活動の把握を目的としたものとしては、衛星写真の夜間光データを用いて工場等の夜間活動の状況を観測する手法[4][5]や、電力需要の高頻度データの変動特性に基づいて、製造業の活動状況を推計する手法が挙げられる[6]。本研究では、日本における製造業の主要業種である自動車工

* Email: d2018ysuimon@socsim.org

業の生産量のナウキャストイング手法を提案する。具体的には、携帯電話端末の位置情報（GPS 情報）を用いることで、大手自動車メーカーの工場の敷地内に滞在している人数を時間帯ごとに計測し、そこから得られる情報を基に、自動車工業の生産状況を推計するモデルの構築する。更に、本手法で計測した自動車メーカーごとの生産状況の趨勢に基づく株式投資戦略を構築することで、株式市場予測における、携帯電話の位置情報に基づく生産量把握の有効性を確認する。

2. 携帯電話 GPS データを用いた分析

人々の行動は何らかの経済活動を反映していることから、その動きをマクロ的に捉えることで、経済動態の計測が可能になろう。その際、有用なのが、人々が保有する携帯電話の位置情報（GPS 情報）である[3]。本研究では、日本の大手携帯電話会社 au の顧客が保有している携帯電話端末の GPS 情報[7]を用いることで、日本における製造業の主要業種である自動車工業の生産量のナウキャストイング手法を提案する。本研究では、同意に基づいて得られた au 社の顧客の携帯端末の位置情報（GPS 情報）を個人が特定できない形式に加工した上で KDDI 社が提供しているデータを使用する。なお本データには、訪日外国人等による日本国内でのローミングサービスの利用者のデータは含まない。



図 1: 日産自動車栃木工場の例

具体的には、携帯電話端末の GPS データに基づいて、大手自動車メーカーの工場の敷地内に滞在している人数を時間帯ごとに計測し、そこから得られる情報を基に、自動車の生産状況の把握を行う。例えば、図 1 に分析対象の一つである日産自動車の栃木工場の地図を示した。そして、工場の敷地内に滞在している人数の日中の推移の例を図 2 に示した。これは GPS データに基づく日産自動車の栃木工場における時間帯別の滞在人数であり、月の一日当たりの

平均値（土日祝日含む）である。これによると、朝 8 時ごろから夕方 17 時ごろまでの間、工場敷地内の滞在人数が多く、その後も、夜間にある程度的人数が滞在していることが分かる。図中では 2020 年と 2019 年の 4 月から 7 月の人数の推移を掲載した。例えば、2020 年 5 月は、敷地内のピーク的人数自体が 2019 年 5 月に比べ 60% 程度に減少している。新型コロナウイルスの感染拡大の影響に伴う、生産活動の低下が表れていたことが窺えよう。2020 年 6 月に入ると、日中的人数にはある程度の戻りが見られたものの、夜間的人数は依然として低水準となっている。

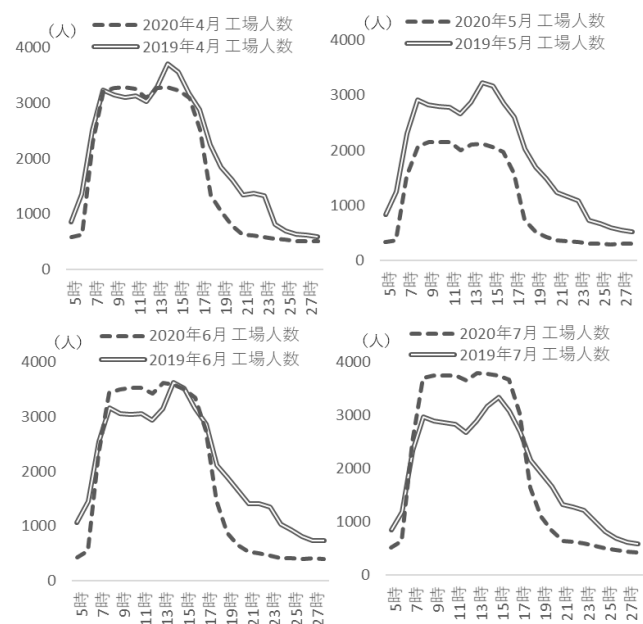


図 2: 日産自動車栃木工場の時間帯別滞在人数

3. 生産量のナウキャストイング

本研究では、大手自動車メーカー各社の完成車の組み立て工場（トヨタは田原、堤、高岡、元町、宮田、大衝、岩手、東富士、富士松、吉原、いなべ、長草とダイハツの池田、本社、京都、大分、滋賀第 1 地区、第 2 地区を合わせた計 18 地点。日産は栃木、追浜、九州、湘南の 4 地点。ホンダは狭山、寄居、鈴鹿の 3 地点。スズキは湖西、相良、磐田の 3 地点。マツダは本社、防府西浦地区、中関地区の 3 地点。三菱は岡崎、水島、坂祝の 3 地点。スバルは矢島の 1 地点）の滞在人数の計測を行い、そこから得られたデータに基づいて各社の自動車生産量の推計を行う。

具体的には、工場ごとに各月の滞在人数（24 時間の毎時間の合計人数）を集計することで、各社の全工場の合計人数を算出した（図 3、6 では「工場人数」と表記）。また、工場によって、工場への来訪者や完成車の組み立て以外の作業の従事者、他社ブランド

車の生産（業績上は製造元の実績となるが、統計上は相手先の生産量に含まれる）を行っている人等が含まれるノイズ要因の存在を考慮し、各社生産量と相関の高い工場の組み合わせを抽出した場合の合計人数に基づく生産量の推計値を算出した（図3、6に「生産量推計値」として掲載）。ここでは、企業ごとに、8時台の人数を用いた場合、22時台の人数を用いた場合、8時台と22時台の平均値を用いた場合について検討し（自動車の組み立て工場での勤務体制として2直シフト制が採用されている点を踏まえ、8時台と22時台の滞在人数に着目）、生産実績値と最も相関の高くなる工場の組み合わせの人数を抽出した。そして、抽出した人数（前年比）を、実績生産量（前年比）の平均と標準偏差が等しくなるように線形変換した値を「生産量推計値」とした。

これらの系列と、自動車メーカー各社の生産量の比較を図3、6に示した。概ねの連動性が確認できよう。更に、工場の滞在人数の集計値に基づくデータと、経済産業省統計の鉱工業生産指数（自動車工業）の関係性も確認するため、全工場の人数を合計した値に加え、前述した相関の高い工場の組み合わせから推計される各社の生産量を合計した値と、鉱工業生産指数（自動車工業）の比較を図3に掲載した。結果、いずれにおいても実績値と推計値の概ねの連動性が確認できよう。




図3：自動車生産量と工場人数に基づく推計値

4. 生産量推計に基づく株式投資戦略

次に、本手法で計測した自動車メーカーごとの生

産状況の趨勢に基づく株式投資戦略を提案したい。そもそも自動車メーカーは、足元の状況に加えて先行きの需要も踏まえて生産量を機動的に調整している可能性があり、その生産量は株価に対して重要な情報を持つことが期待される。この点を踏まえ、本研究では、毎月初に前月までの生産量に基づいてポジションを決定する投資戦略について検討する。

具体的には、四半期ベースの生産量の前年比前期差を各社間で比較することで、毎月投資ポジションを決定する。例えば2020年4月初のポジションを決定する際は、2020年1～3月の生産量（前年比）と2019年10～12月の生産量（前年比）の差を各社について算出し、その大小関係からポジションを決定する。なお、毎月の各社生産量が公表されるのは翌月末であるため、月初の時点では前月の生産量を直接参照することは出来ない。ここでは、前月の生産量として、各社ごとに前章で示した工場の合計人数から推計される値（前月までの生産量（前年比）と平均と標準偏差が等しくなるような線形変換を行うことで当月の生産量を推計した値）を使用する。




図4：投資戦略シミュレーション（ロング&ショート）

図4に、本分析で対象とする全7社の株式銘柄のうち、指標の上位3銘柄をロングし、下位3銘柄をショートした場合の累計リターンの推移を示した。本分析では、工場人数の前年比データを利用できるのが2019年2月以降とサンプル数が少ないため、前月の生産量データを所与とした場合の仮想的なパフォーマンスも併せて掲載した。長期にわたる堅調なパフォーマンスが確認できるだろう。また、ロング・ショートする対象銘柄ごとの累積リターンを図5に掲載した。相対的に生産量が増加し続けている銘柄が、減少し続けている銘柄を安定してアウトパフォームしていることが見て取れる。更に、推計値を投資判断に用いたケースでも、前月の実際の生産量を所与とした場合とほとんど変わらないパフォーマンス

スを示しており、携帯電話の位置情報から工場人数を把握することの株式投資戦略における有効性が窺えよう。




図 5: 投資戦略シミュレーション
(ロング・ショートの内訳)

5. 結論

本研究では、日本における製造業の主要業種である自動車工業の生産量のナウキャスト手法を提案した。具体的には、携帯電話端末の位置情報（GPS 情報）を用いることで、大手自動車メーカーの工場の敷地内に滞在している人数を時間帯ごとに計測し、そこから得られる情報を基に、自動車工業の生産状況を推計するモデルの構築を行った。これにより、高い速報性を保ちつつ、大手自動車各社の生産量の概ねの推計に成功した。更に本研究では、同情報が示すメーカーごとの生産状況の趨勢に基づく株式投資戦略を構築することで、堅調なパフォーマンスを確認した。このことは、株式市場予測における、携帯電話の位置情報に基づく生産量把握の有効性を示す結果と言えよう。

参考文献

- [1] 水門善之, 柳井都古杜, ビジネスデータを用いた消費のナウキャスト, JCB 消費 NOW, 2019
<https://www.jcbconsumptionnow.com/info/news-54>
- [2] 渡辺努, 経済ナウキャストの時代, 公研 2016 年 4 月号, 2016, <http://www.price.e.u-tokyo.ac.jp/img/news/np-080.pdf>
- [3] 水門善之, 柳井都古杜, 携帯電話 GPS データを用いた経済活動分析と COVID-19 の影響分析, 人工知能学会第 120 回知識ベースシステム研究会, pp.1-4, 2020
- [4] 水門善之, 福馬智生, 人工衛星の夜間光画像を用いた製造業の業種別の生産活動分析, 人工知能学会第 117 回知識ベースシステム研究会,

pp.25-27, 2019

- [5] 倉田正充, 低所得国における夜間光と社会・経済指標の相関関係, 上智経済論集, Vol62 (1・2), pp.19-26, 2017
- [6] 水門善之, 和泉潔, 坂地泰紀, 島田尚, 松島裕康, 高頻度電力需要データを用いた製造業活動のナウキャストモデルの構築, 人工知能学会第 35 回社会における AI 研究会, 35 巻 1 号, pp.1-5, 2019
- [7] KDDI Location Analyzer
- [8] e-AURORA 株価データ
- [9] OpenStreetMap contributors

謝辞

本研究において、分析対象とした自動車工場の選択に関して、野村證券自動車セクターアナリスト梶本将隆氏より助言を頂いた。ここに記して感謝したい。

Appendix.

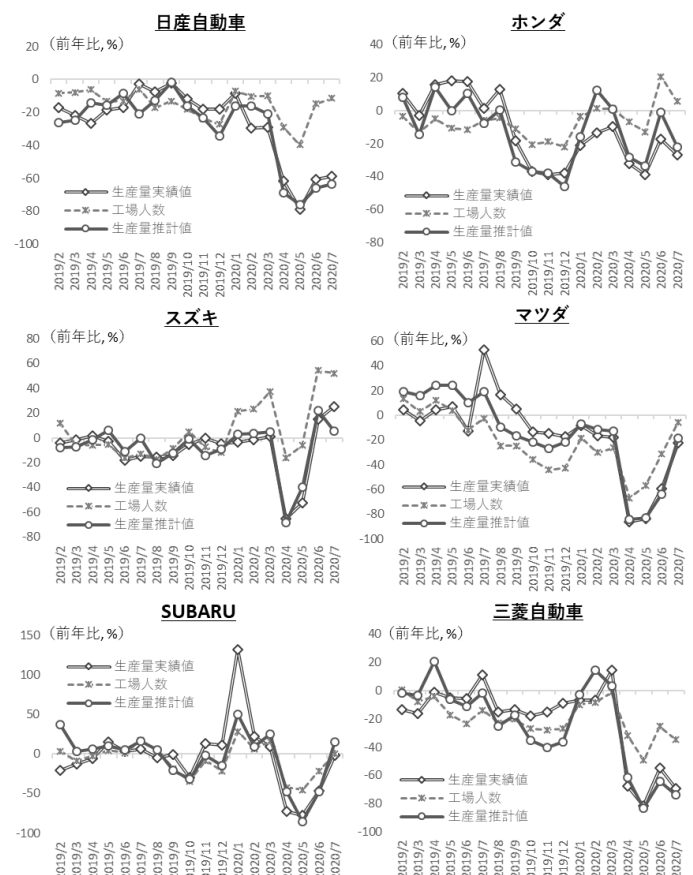


図 6: 大手自動車メーカーの生産量と
工場人数に基づく推計値

コロナショック環境下における AI トレーダーの投資パフォーマンス

Investment performance of AI traders under COVID-19 Crisis

石原 龍太*

Ryota Ishihara

株式会社かんぽ生命保険 運用企画部

Investment Planning Department, JAPAN POST INSURANCE Co., Ltd.

Abstract: In This paper, the investment performances of the AI traders that predict fluctuations in Nikkei 225 Futures during the period under COVID-19 Crisis were measured. In addition, by comparing the data under the Lehman Shock with “learned AI traders” and “not learned AI traders”, learning of past market crash could improve the investment performance of AI traders in future market crash. Furthermore, it was confirmed that AI traders who have learned the period of the Lehman shock were more likely to avoid risk when the market fluctuation range was small.

1 はじめに

金融機関では現在、いわゆるフィンテックの進展の中で、融資判断や保険金支払査定、不正取引の検知など幅広い業務において、人工知能（以下、AI）の実務への応用が進んでいる。資産運用においても、将来の株価や金利を予測する試み、例えば、株価や金利の推移、各国経済指標の変化など様々な時系列データを AI に学習させて、予測対象の数値に影響を与える変数を見つけ出す、といった研究が行われており、こうした研究をもとにした AI 運用モデルの開発や活用が急速に進んでいる。

一方、こうした時系列データを始めとする過去のデータに基づいて出力を得るモデルに対しては、過去に例を見ない市場環境下では有効に機能しない、とする批判もある。2020 年初頭に発生した新型コロナウイルスによる金融市場の混乱（以下、コロナショック）は、ここ数年の間に急増した AI 運用モデルが初めて経験する「ブラック・スワン¹」であり、その多くが市場環境の急激な変化に苦戦し、大きな損害を被ったといわれる。

筆者は以前、日経 225 先物価格の変動を予測する AI トレーダーを構築し、その投資パフォーマンスを計測したが、そこで行った AI トレーダーの投資シミュレーションは、コロナショック発生前（2019 年 9

月以前）のデータを用いたものであった。本稿では、コロナショック発生前のデータに加えて、コロナショックが発生した 2019 年 10 月以降のデータを用いた投資シミュレーションを行い、その投資パフォーマンスを計測する。

2 AI トレーダー

本稿では、石原（2020）の AI トレーダー（日経 225 先物価格²の変動予測モデル）を構築し、投資シミュレーションを行う。

この AI トレーダーは、7 層（入力層が 1 層、中間層が 5 層、出力層が 1 層）からなる順伝播型のニューラルネットワークの投資判断アルゴリズム（図 1）をもち、直近の市場データから将来の日経 225 先物価格の変動を予測する。また、過去の市場データを事前に学習することで、日経 225 先物価格の変動に対する予測精度をもった投資判断アルゴリズムを経験的に獲得することができる。

なお、AI トレーダーの詳細についての説明は、石原（2020）を参照されたい。

2.1 入力変数（市場データ）

AI トレーダーの入力変数である市場データには、大阪取引所の日中立会における日次の四本値³を用


* 連絡先: ryouta.ishihara.hw@jp-life.jp

¹ マーケットにおいて「確率論や従来の知識や経験からは予測できない極端な事象の発生」を指して使われる言葉。

² AI トレーダーの予測対象銘柄は、大阪取引所で取引される日経 225 先物（ラージ）の期近限月とする。

³ 時点 t における日経 225 先物の四本値を「 $NKfOP_t$: 始値, $NKfHI_t$: 高値, $NKfLO_t$: 安値, $NKfCL_t$: 終値」

図1 AIトレーダーの投資判断アルゴリズム



(注) 丸はノード，矢印はノード間の結合と処理の流れを示す。
(出所) 石原 (2020)

表1 入力層ノードの出力値

ノード	計算式
y_{1t}^{in}	$\log(NKfCL_t / NKfOP_{t-1})$
y_{2t}^{in}	$\log(NKfCL_t / NKfHI_{t-1})$
y_{3t}^{in}	$\log(NKfCL_t / NKfLO_{t-1})$
y_{4t}^{in}	$\log(NKfCL_t / NKfCL_{t-1})$
y_{5t}^{in}	$\log(NKfCL_t / NKfOP_t)$
y_{6t}^{in}	$\log(NKfCL_t / NKfHI_t)$
y_{7t}^{in}	$\log(NKfCL_t / NKfLO_t)$

いる。AIトレーダーは、投資判断アルゴリズムの入力層ノード y_{kt}^{in} において直近の市場データを認識し、表1の計算式による出力値を後続層のノードに受け渡すものとする。

2.2 投資判断の導出

AIトレーダーは、自身の投資判断アルゴリズムにおいて将来の日経225先物価格の変動（上昇または下落）を予測し、当該予測結果から投資判断（上昇を予測：買，下落を予測：売）を導出する。また、導出した投資判断に基づき、ポジションのリバランス⁴を行うものとする。

のように表現する。

⁴ リバランスの取引は、投資判断を行なった日の大引（終値）で行うものとする。なお、AIトレーダーが行う取引は、“新規買”と“返済売”のみとする（売建のポジションはとらない）。

2.3 事前学習

AIトレーダーは、過去の市場データを事前学習することで、日経225先物価格の変動に対する予測精度をもった投資判断アルゴリズムを経験的に獲得する。

なお、AIトレーダーの事前学習は、訓練データ（過去の市場データ）を学習データと検証データに分別し、①学習（予測精度の高い投資判断アルゴリズムの探索⁵）、②検証（①で探索した投資判断アルゴリズムが、学習データに過学習していないかの確認）、の2ステップにより行うものとする。

3 投資シミュレーション

前章のAIトレーダーについて、コロナショック発生前の株価上昇局面（2016年10月～2019年9月）及びコロナショックによる市場混乱局面（2019年10月～2020年6月）のデータを用いて投資シミュレーションを行う。

3.1 適用データ及びシミュレーション手順

(1) 適用データ

本稿の投資シミュレーションには、次の評価データを用いる。

株価上昇局面：2016年10月～2019年9月
市場混乱局面：2019年10月～2020年6月

なお、AIトレーダーの事前学習には、表2の訓練データを用いる。

表2 訓練データ

	期間
学習データ	2007年10月～2013年9月
検証データ	2013年10月～2016年9月

(2) シミュレーション手順

投資シミュレーションは次の手順により行う。①まず5個体のAIトレーダーを構築し、表2の訓練データを用いて事前学習を行う。②次に事前学習を行なったAIトレーダーについて、評価データを用いて株価上昇局面及び市場混乱局面における投資シミュレーションを行う。③そして、両局面におけるAI

⁵ 予測精度の評価に用いる適合度の計算には、インフォメーションレシオをベースにした算式を用いる。

トレーダーの日経 225 先物に対するリスク調整後リターン α を計測⁶し、その予測精度を評価する。

3.2 シミュレーション結果

(1) 株価上昇局面

コロナショック前の株価上昇局面における投資シミュレーション結果を図2及び表3に示す。当該局面におけるAIトレーダーの収益率は、平均で8.21%と日経 225 先物よりも低い水準であった。

AI トレーダーの α は半数以上の個体がプラスであった一方、平均が若干のプラスにとどまったことから、AI トレーダーはコロナショック前の株価上昇局面において、ある程度の予測精度を示したもののその水準は高くないといえる。

図2 収益率の推移（株価上昇局面）




表3 投資パフォーマンス（株価上昇局面）

	収益率 (年率)	標準偏差 (年率)	α (年率)	β	決定係数
AI トレーダー1	12.07%	14.67%	2.23%	0.86	0.74
AI トレーダー2	14.35%	12.97%	5.41%	0.78	0.78
AI トレーダー3	5.17%	9.00%	0.25%	0.43	0.49
AI トレーダー4	3.15%	11.54%	-4.75%	0.69	0.77
AI トレーダー5	6.30%	10.65%	0.27%	0.52	0.53
平均	8.21%	11.77%	0.68%	0.65	0.66
標準偏差	4.77%	2.17%	3.69%	0.18	0.14
日経 225 先物	11.51%	14.74%	-	-	-

⁶ α の値は、回帰式「AI トレーダーの月次収益率 $=\alpha+\beta\times$ 日経 225 先物の月次収益率 $+\varepsilon$ 」により推定する。

また、AI トレーダーの β は平均で0.65（各個体の β は0.43～0.86）と、マーケットリスクをやや抑えた運用をしていた。

(2) 市場混乱局面

コロナショックによる市場混乱局面における投資シミュレーション結果を図3及び表4に示す。当該局面におけるAIトレーダーの収益率は、平均で17.49%と日経 225 先物を大きく上回った。

AI トレーダーの α はすべての個体がプラスであった上、平均も12.92%と高かったことから、AI トレーダーはコロナショックによる市場混乱局面において、高い予測精度を示したといえる。

また、AI トレーダーの β は平均で0.69と、株価上昇局面とほぼ同水準であったものの個体差によるばらつきが大きく、5個体のうち3個体は0.88～1.01と日経 225 先物とほぼ同程度のマーケットリスクをとっていた一方、残りの2個体は0.26～0.35とマーケットリスクを抑えた運用をしていた。

図3 収益率の推移（市場混乱局面）




表4 投資パフォーマンス（市場混乱局面）

	収益率 (年率)	標準偏差 (年率)	α (年率)	β	決定係数
AI トレーダー1	19.97%	23.90%	13.27%	1.01	0.87
AI トレーダー2	29.13%	22.33%	26.81%	0.35	0.12
AI トレーダー3	3.40%	10.17%	1.68%	0.26	0.32
AI トレーダー4	21.33%	21.64%	15.13%	0.93	0.91
AI トレーダー5	13.60%	21.85%	7.72%	0.88	0.80
平均	17.49%	19.98%	12.92%	0.69	0.60
標準偏差	9.62%	5.55%	9.37%	0.35	0.36
日経 225 先物	6.65%	22.13%	-	-	-

4 訓練データの違いによる影響

前章の投資シミュレーションにおいて、AIトレーダーの事前学習に用いた訓練データには2008年のリーマンショック発生時期を含んでいた。このAIトレーダーは、過去データから経験的に予測精度を獲得するものであることから、リーマンショックによる市場混乱局面を事前学習したことが、コロナショックによる市場混乱局面において、AIトレーダーが高い予測精度を示した理由の1つであると推察する。

そこで本章では、リーマンショックによる市場混乱局面を学習しないAIトレーダー（学習なしAI）を構築し、前章で構築したリーマンショックによる市場混乱局面を学習したAIトレーダー（学習ありAI）と比較することで、過去の市場混乱局面の学習の有無がAIトレーダーの投資パフォーマンスや投資行動に与える影響について確認する。

4.1 学習なしAIの構築

(1) 事前学習

学習なしAIの事前学習には、表5の訓練データ（リーマンショック発生時期を含まないデータ）を用いる。なお、学習なしAIと学習ありAIの訓練期間と投資シミュレーション期間の関係は、図4のように表すことができる。


(2) シミュレーション手順

学習なしAIの投資シミュレーションは、次の手順により行う。①まず5個体のAIトレーダーを構築し、表5の訓練データを用いて事前学習を行う。②次に事前学習を行なったAIトレーダーについて、前章と同じ評価データを用いて、株価上昇局面及び市場混乱局面における投資シミュレーションを行う。③次に日経225先物に対する α を計測し、その予測精度を評価する。

表5 訓練データ（学習なしAI）

期間	
学習データ	2008年11月～2013年9月
検証データ	2013年10月～2016年9月

図4 訓練期間と投資シミュレーション期間の関係



4.2 学習なしAIのシミュレーション結果

(1) 株価上昇局面

コロナショック前の株価上昇局面における投資シミュレーション結果を図5及び表6に示す。当該局面における学習なしAIの収益率は平均で11.08%と、日経225先物とほぼ同水準であった。

学習なしAIの α は半数以上の個体がプラスであった一方、平均が若干のプラスにとどまったことから、学習なしAIはコロナショック前の株価上昇局面において、ある程度の予測精度を示したもののその水準は高くはないといえる。

また、学習なしAIの β は平均で0.89（各個体の β は0.76～1.01）と、日経225先物とほぼ同程度のマーケットリスクをとっていた。

図5 収益率の推移（株価上昇局面）




表6 投資パフォーマンス（株価上昇局面）

	収益率 (年率)	標準偏差 (年率)	α (年率)	β	決定係数
AIトレーダー1'	11.45%	15.39%	0.43%	0.96	0.84
AIトレーダー2'	12.48%	13.30%	2.79%	0.84	0.87
AIトレーダー3'	12.39%	13.11%	3.61%	0.76	0.73
AIトレーダー4'	8.50%	14.01%	-1.68%	0.88	0.87
AIトレーダー5'	10.60%	15.11%	-0.98%	1.01	0.96
平均	11.08%	14.18%	0.83%	0.89	0.85
標準偏差	1.63%	1.03%	2.31%	0.10	0.08
日経225先物	11.51%	14.74%	-	-	-

(2) 市場混乱局面

コロナショックによる市場混乱局面における投資シミュレーション結果を図6及び表7に示す。当該局面における学習なしAIの収益率は平均で8.23%と、日経225先物よりもやや高い水準であった。

学習なしAIの α は平均が1.91%とプラスになった一方、個体差によるばらつきが大きく、一部には大きくマイナスとなる個体もあったことから、学習なしAIの市場混乱局面に対する予測精度を明確に示すものではなかった。

また、学習なしAIの β は平均で0.95（各個体の β は0.70～1.17）と、株価上昇局面と同様にマーケットとほぼ同程度のリスクをとっていた。

4.3 両AIトレーダーの投資パフォーマンスの比較

(1) 株価上昇局面

コロナショック前の株価上昇局面における両AIトレーダーの投資パフォーマンスを図7及び表8に示す。学習なしAIの β が相対的に高い水準であったこともあり、学習ありAIは学習なしAIと比較して、

図6 収益率の推移（市場混乱局面）




表7 投資パフォーマンス（市場混乱局面）

	収益率 (年率)	標準偏差 (年率)	α (年率)	β	決定係数
AI トレーダー1'	-8.74%	28.33%	-16.53%	1.17	0.84
AI トレーダー2'	15.09%	21.25%	9.60%	0.83	0.74
AI トレーダー3'	0.63%	24.31%	-6.36%	1.05	0.91
AI トレーダー4'	22.49%	19.73%	17.85%	0.70	0.61
AI トレーダー5'	11.70%	23.69%	4.99%	1.01	0.89
平均	8.23%	23.46%	1.91%	0.95	0.80
標準偏差	12.33%	3.29%	13.52%	0.19	0.12
日経 225 先物	6.65%	22.13%	-	-	-

当該局面における収益率が低いことがわかる。

α については、学習なしAIのほうがやや高い水準であったものの、個体差によるばらつき（標準偏差）を勘案すると、AIトレーダーの予測精度には、過去の市場混乱局面の学習の有無による差異は生じていないと考える。

また、 β については、学習なしAIのほうが高い水準であったことから、過去の市場混乱局面を学習したAIトレーダーは、マーケットリスクを抑える傾向にあるといえる。

(2) 市場混乱局面

コロナショックによる市場混乱局面における両AIトレーダーの投資パフォーマンスを図8及び表9に示す。学習ありAIは学習なしAIと比較して、当該局面における収益率が高いことがわかる。

α については、学習ありAIのほうが高い水準であることが確認できる。このことから、AIトレーダーは過去の市場混乱局面を学習することで、将来の市場混乱局面に対する予測精度を向上させるものと考ええる。

また、 β については、学習なしAIのほうが高い水準であったことから、過去の市場混乱局面を学習したAIトレーダーは、株価上昇局面と同様に、マーケットリスクを抑える傾向にあるといえる。

図7 両AIトレーダーの平均収益率（株価上昇局面）



表8 両AIトレーダーの投資パフォーマンス（株価上昇局面）

	収益率 (年率)	標準偏差 (年率)	α (年率)	β	決定係数
学習あり AI	8.21%	11.77%	0.68%	0.65	0.66
	(4.77%)	(2.17%)	(3.69%)	(0.18)	(0.14)
学習なし AI	11.08%	14.18%	0.83%	0.89	0.85
	(1.63%)	(1.03%)	(2.31%)	(0.10)	(0.08)

(注) 上段の値は平均、下段の括弧内の値は標準偏差。

図 8 両 AI トレーダーの平均収益率（市場混乱局面）

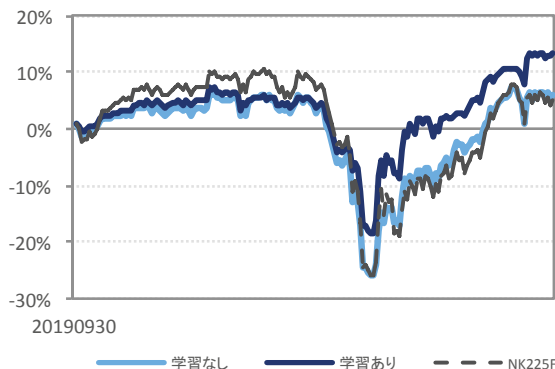


表 9 両 AI トレーダーの投資パフォーマンス（市場混乱局面）

	収益率 (年率)	標準偏差 (年率)	α (年率)	β	決定係数
学習あり AI	17.49% (9.62%)	19.98% (5.55%)	12.92% (9.37%)	0.69 (0.35)	0.60 (0.36)
学習なし AI	8.23% (12.33%)	23.46% (3.29%)	1.91% (13.52%)	0.95 (0.19)	0.80 (0.12)

(注) 上段の値は平均，下段の括弧内の値は標準偏差。

4.4 両 AI トレーダーの投資行動の比較

最後に，学習あり AI と学習なし AI の投資行動を比較し，どのような差異が見られるか確認する。

両 AI トレーダーの入力層ノードの出力値と平均ポジション⁷の関係を図 9 及び図 10 に示す。これらの関係から，AI トレーダーがポジションを落とす投資行動をとるのは，各入力層ノードとも出力値が 0% 近辺となる場合に偏っていることがわかる。これは，AI トレーダーには「直近の市場変動幅が小さい場合において，日経 225 先物価格の下落を警戒し，リスク回避的な投資行動をとる」傾向があることを示しており，学習あり AI ではその傾向がより顕著に見られた。ただし，入力層ノードの出力値が 0% 近辺となる場合であっても AI トレーダーがポジションを落としていないケースも少なくないことから，直近の市場変動幅の他に，AI トレーダーの投資行動に影響を与える何らかのファクター（因子）が存在するものと考えられる。

⁷ 平均ポジションは「(AI トレーダー1 のポジション + … + AI トレーダー5 のポジション) ÷ 5」の式により計算する。

5 おわりに

本稿では，石原(2020)の研究で構築した AI トレーダーについて，コロナショックによる市場混乱局面における投資パフォーマンスを計測し，AI トレーダーが当該局面における予測精度を有していることを確認した。また，リーマンショックによる市場混乱局面を学習した AI トレーダーと学習していない AI トレーダーの投資パフォーマンスを比較し，AI トレーダーが過去の市場混乱局面を学習することで，将来の市場混乱局面に対する予測精度を向上させることを確認した。さらに，AI トレーダーの入力層ノードの出力値と平均ポジションの関係性から，過去の市場混乱局面を学習した AI トレーダーは，学習していない AI トレーダーに比べて，直近の市場変動幅が小さい場合にリスク回避的な投資行動をとる傾向が強いことを確認した。

これらの結果は，市場混乱局面における価格変動を説明するファクターの存在を示唆するものであり，日経 225 先物の価格変動メカニズムを解明する上で有用な手がかりになる可能性があるものと考えられる。

なお，今回は日経 225 先物価格の変動を直近の四本値データから予測する AI トレーダーを分析の対象としたため，本稿で扱わなかった非構造化データ（テキストや画像等）や金融資産（為替や金利等）への応用が，今後の課題としてあげられる。

本稿の内容は，筆者個人に属するものであり，筆者の所属組織の公式見解を示すものではありません。また，本稿に含まれる誤りは全て筆者の責に帰するものです。

参考文献

- [1] 石原龍太，“感度分析による AI トレーダーの投資判断アルゴリズムの解釈”，先物オプションレポート 2020 年 1 月号，(2020)
- [2] 笠井彰吾，“金融サービスをめぐる AI 活用の経緯 -AI 技術の現状を踏まえて-”，立法と調査 2018.10 No. 405，(2018)
- [3] 野首文徳，“AI 活用型ファンドの動向とスタイル”，日興リサーチレビュー 2020 年 3 月，(2020)

図9 入力層ノードの出力値と平均ポジション
(学習あり AI)





図10 入力層ノードの出力値と平均ポジション
(学習なし AI)



強化学習を用いたライフサイクル投資

Life-Cycle Investment with Reinforcement Learning

上田 翼^{1*}
Tsubasa Ueda¹

¹ 三井住友 DS アセットマネジメント株式会社
¹ Sumitomo Mitsui DS Asset Management Company, Limited

Abstract: 個人のライフサイクルを前提として長期投資を考える場合、通常の分散分析アプローチとは異なり多期間最適化の視点が必要となる。より現実的に即した仮定の下で、強化学習を用いて構築した投資ポートフォリオは典型的な手法より優れた生涯効用を達成し得ることを検証する。

1 はじめに

個人の生涯を通じた資産配分を考えるライフサイクル投資と呼ばれる分野がある。通常の平均分散アプローチでは、投資期間は1期のみであり、期末に全ての富を消費することが暗黙裡に仮定されている。しかしながら、現実の消費は複数の期間にわたって行われるため、長期投資においては毎期の消費と投資ポートフォリオを同時に考慮する多期間最適化の視点が必要となる。比較的単純な仮定の下では、Merton[1]が連続時間、Samuelson[2]が離散時間の枠組みにおいて最適消費比率、リスク資産への最適投資比率の解析解を明らかにした。その後、多くの研究によって、効用関数の修正、消費制約の追加、投資資産の拡大といった拡張が試みられてきた。しかし、大半は状態と行動を離散化したうえで価値関数をモンテカルロ法で計算しており、離散化基準の恣意性やリスク情報の欠落、扱える次元の制約といった課題が存在する。

近年発展している深層強化学習の分野では、価値関数をニューラルネットワーク等で近似することで、連続な状態行動空間において幅広い問題を解くことが可能となった。それゆえ、より柔軟な仮定の下でライフサイクル投資にアプローチできる可能性が期待される。実際に[3]では、GJR-GARCH型の株価とHull-Whiteモデルに従う金利などを仮定し、強化学習を用いて退職世代の最適消費・投資を分析している。

本稿では、金利のダイナミクスとして実務で一般的なNelson-Siegel型のイールドカーブモデルを導入したうえで、労働収入により資産を蓄積する現役世代まで対象を広げ、消費と投資ポートフォリオの分析を行う。強化学習モデルによる投資戦略は、60/40ポートフォリオやターゲット・デット・ファンドなどの典型的な手法よりも優れた生涯効用を達成し得ることを検証する。

2 ライフサイクルと資産価格モデル

2.1 ライフサイクル

個人は22歳で保有資産0の状態から労働を開始し、賃金収入を得て消費を行いながら余剰資産を投資する。65歳で退職して以降は年金を受給しつつ、現役世代と同様に消費と投資を続ける。投資対象は株式と債券（デュレーション1~30年を同時に選択）であり、消費および投資ポートフォリオの意思決定は年に1回行われる。最大寿命を105歳とし、一般的な死亡率に従い毎期確率的に逝き、残された資産は遺産となる。

2.2 効用関数

消費効用関数として、次のような相対的リスク回避度 γ が一定である関数を仮定する。

$$u_c(c) = \frac{c^{1-\gamma} - 1}{1-\gamma} \quad (c > 0)$$

同様に、遺産効用関数として、次のような相対的リスク回避度 γ が一定で遺産選好 ϕ をもつ関数を仮定する。

$$u_b(b) = \frac{b^{1-\gamma}}{1-\gamma} \left(\frac{\phi}{1-\phi} \right)^\gamma - \frac{1}{1-\gamma} \quad (b > 0)$$

x 歳を開始年齢として、消費効用と遺産効用を合わせた期待生涯効用を次のように定義する。[4]

$$E \left[\sum_{t=0}^T t p_x u_c(c_t) + t_{-1} q_x u_b(b_t) \right] \quad (1)$$

$t p_x$ は x 歳時に生存している場合に $x+t$ 歳に生存している確率であり、 $t_{-1} q_x$ は x 歳時に生存している場合に $(x-t-1, x-t]$ 歳で死亡する確率である。個人は期待生涯効用を最大化するように意思決定を行う。なお、本稿では $\gamma = 10$ とあらかじめ設定している。

*tsubasa.ueda@smd-am.co.jp, tsubasa.ud@gmail.com

2.3 収入

現役時の賃金は一般的な大学学卒男性の賃金カーブを想定し、退職時には初任給対比で平均 8 倍の退職金を受け取ると仮定した。毎年の賃金は景気による賞与変動を捉えるため株価と相関 $\rho_{stock,wage} = 0.3$ を持つ誤差項 ϵ_{wage} を加え、退職金には個人の異質性を反映して独立な誤差項 $\epsilon_{package}$ を加える。退職後は初任給対比で 75%の固定的な年金を受給し続ける。

2.4 株式

株式は、年金積立金管理運用独立行政法人 (GPIF) の基本ポートフォリオが依拠する前提 [5] を参考に、年間期待リターンを 5.6 %、年間標準偏差を 23.14 % とした。リターン分布は正規分布を仮定した。

2.5 債券


イールドカーブのダイナミクスとして、次のような動学的 Nelson-Siegel モデルを想定する。[6]

$$r_{\tau,t} = \beta_{t,1} + \beta_{t,2} \frac{1 - e^{-\lambda\tau}}{\lambda\tau} + \beta_{t,3} \left(\frac{1 - e^{-\lambda\tau}}{\lambda\tau} - e^{-\lambda\tau} \right) + \epsilon_{\tau,t}$$

$$\beta_t - \mu = A(\beta_{t-1} - \mu) + \xi_t$$

$r_{\tau,t}$ は時点 t の年限 τ の金利を指し、 $\beta_t = (\beta_{t,1}, \beta_{t,2}, \beta_{t,3})$ は $\mu = (\mu_1, \mu_2, \mu_3)$ に平均回帰する VAR(1) 過程に従う。誤差項 $\epsilon_{\tau,t}$ は互いに独立だが、 $\xi_{t,j} (j = 1, 2, 3)$ は互いに相関を仮定する。状態空間モデルを用いて、日本の 2000 年 1 月～2020 年 8 月の月次データをもとにパラメーターを推定した。生成したイールドカーブの 7 年間の推移例を図 1 に示す。債券はイールドカーブの変化に従い価格が変動するためリスク性資産となるが、デレションが短期化するにつれてリスクは低下していく。特に 1 年債は投資時点でリターンが確定することから実質的に無リスク資産とみなせる。

図 1: イールドカーブの推移例



3 強化学習モデル

3.1 状態行動空間

状態空間と行動空間を次のように定義する。

$$s_t \in \mathcal{S} := \mathcal{Z} \times \mathcal{R} \times \mathcal{R}^3$$

$$= \{(l, w, \beta) \mid l, w \geq 0\}$$

$$a_t^\pi(s_t) \in \mathcal{A} := \mathcal{R} \times \mathcal{R} \times \mathcal{R}$$

$$= \{(\alpha, \delta, \tau) \mid 0 < \alpha < 1, 0 \leq \delta \leq 2, 1 \leq \tau \leq 30\}$$

l は最大余命、 w は保有資産、 β は前述したイールドカーブの状態を表している。エージェントは每期これらの状態を観察し、以下の行動を決定する。 α は資産に占める消費の比率である。 δ は投資に占める株式の比率であり、最近のレバレッジ型投信の普及を踏まえて、 δ の上限は 2 としている。ただし、レバレッジ部分については手数料率 $r_{leverage} = 0.01$ を支払う。 τ は債券の投資デレションであり、最大を 30 (年) とした。

3.2 アルゴリズム

学習には PPO(proximal policy optimization) を用いる。生涯期待効用 (1) の最大化に対応するよう、開始時点の年齢 $x = 22$ として報酬を次のように定義する。

$$r_t = p_x u_c(c_t) + q_{t-1} u_b(b_t)$$

PPO の方策関数と価値関数は、ユニット数 64、レイヤー数 2 の隠れ層からなる全結合型ニューラルネットワークで構成する。PPO のパラメータは次の目的関数を最大化するように更新される。[7]

$$L_t^{CLIP+VF+S}(\theta) = \hat{E}_t[L_t^{CLIP}(\theta) - c_1 L_t^{VF}(\theta) + c_2 S[\pi_\theta](s_t)]$$

L_t^{CLIP} はクリップされた代理目的関数、 L_t^{VF} は価値関数の二乗誤差、 S はエントロピーボーナスである。 c_1 は価値関数係数、 c_2 はエントロピー係数であり、ハイパーパラメータとして扱われる。

4 シミュレーション

4.1 手順

前述のライフサイクルと資産価格モデルに基づいて、学習用データを 300,000 エピソードを生成する。各エピソードは開始年齢 22 歳から最大寿命 105 歳に至る 84 ステップから構成される。前述の強化学習モデルを用いて学習を行う。学習完了後、テストデータとして 1,000 エピソードを生成する。学習済みのモデルに加え

て、ベンチマークとして①60/40 ポートフォリオと②シンプルなターゲット・デット・ファンドのケースも評価を行う。

4.2 学習結果

図2と図3は、それぞれ資産と消費の生涯パスの5%点、中央値、95%点を表している。横軸は労働開始からの経過年に対応する。なお、相対的にリスク回避度一定の効用関数を仮定しているため、縦軸の水準はスケール不変である。資産は、労働を開始し10年程度経過してから徐々に蓄積が始まり、退職給付を得た時点が概ねピークとなって次第に取り崩される。消費は退職時まで概ね横ばいで推移し、退職後の資産状況に応じて徐々に増やしていく形となっている。

図 2: 資産




図 3: 消費




図4と図5からは投資ポートフォリオの状況がわかる。株式投資比率は労働開始後10年から20年の間に急上昇し、以降は横ばいで推移する。晩年に至ると比率が急低下しているが、資産が取り崩されてバッファが減ったことや遺産動機が相対的に優勢になることが

関係していよう。債券デュレーションは、当初は高水準ながら退職時にかけて緩やかに低下しており、ポートフォリオ全体のリスクを抑制している。株式投資比率ではなくデュレーションを用いたリスクコントロールはあまり一般的ではないが、本稿では平均回帰型のイールドカーブモデルを用いていることから債券価格にわずかな予測可能性が生まれるため、安定的な投資として債券が選好された可能性があろう。晩年になるとデュレーションは再び上昇するが、株式投資比率の低下と対になっており同じ背景があると考えられる。

図 4: 株式投資比率





図 5: 債券デュレーション



4.3 ベンチマーク比較

学習した消費モデルを固定しつつ、投資モデルのみベンチマークに変更して評価を行う。60/40 ポートフォリオは主に米国で退職世代の安定的なポートフォリオとして推奨されており、株式投資比率 δ は 0.6 に固定する。ターゲットデット型ファンド (TDF) は年齢が上がるにつれて株式投資比率を低下させていくが、今回は”rule of thumb”として有名な $\delta = 1 - \text{年齢}/100$ を用いる。ベンチマークの債券デュレーション τ は、ラ

ンダムに選択するものとする。

生涯効用の平均値と標準偏差は表 1 の通りである。学習モデルの平均が最も高く、標準偏差が最も低い。60/40 ポートフォリオは平均が最も低く、標準偏差が最も高い。TDF の平均は学習モデルと遜色ないが、標準偏差がやや高く、資産価格の変動に左右されやすい。以上のことから、強化学習により構築した投資戦略は、典型的な投資ポートフォリオより生涯効用の観点で優位になり得るといえよう。もっとも、これらの投資戦略の違いがもたらす生涯効用の差自体はそれほど大きくなく、生涯効用は消費（貯蓄）のあり方の影響が大きい可能性もあろう。

表 1: 生涯効用

	学習モデル	60/40	TDF
平均	7.41275	7.41251	7.41274
標準偏差	0.00066	0.00152	0.00073

5 結論

本稿では、強化学習を用いて、ライフサイクル投資の観点から最適な消費とポートフォリオを検討した。より現実 に即した、柔軟性の高い仮定と連続な状態行動空間のもとで、学習したモデルは典型的なポートフォリオと比べて優れた生涯効用を獲得した。もっとも、資産価格のダイナミクスや学習アルゴリズムを網羅的に検討したわけではなく、結果は幅をもってみる必要がある。

参考文献

- [1] Merton, Robert C. "Lifetime portfolio selection under uncertainty: The continuous-time case." *The review of Economics and Statistics* (1969): 247-257.
- [2] Samuelson, Paul A. "Lifetime portfolio selection by dynamic stochastic programming." *The review of economics and statistics* (1969): 239-246.
- [3] Gordon Irlam. "Machine Learning for Retirement Planning." *The Journal of Retirement* 8 (1) (2020): 32-39.
- [4] Bell, David, Estelle Liu, and Adam Shao. "Member's Default Utility Function for Default Fund Design Version 1 ("MDUF v1") Technical Paper No. 3: Optimal Dynamic Strategies." *dynamics* 50 (2017): 2-2.
- [5] 年金積立金管理運用独立行政法人. "基本ポートフォリオの変更について (詳細)" <https://www.gpif.go.jp/topics/Adoption%20of%20New%20Policy%20Portfolio-Jp.details.pdf>.
- [6] Diebold, Francis X., and Canlin Li. "Forecasting the term structure of government bond yields." *Journal of econometrics* 130.2 (2006): 337-364.
- [7] Schulman, John, et al. "Proximal policy optimization algorithms." *arXiv preprint arXiv:1707.06347* (2017).
- [8] 安達智彦, 池田昌幸: 『長期投資の理論と実践』東京大学出版会 (2019)
- [9] Gourinchas, Pierre- Olivier, and Jonathan A. Parker. "Consumption over the life cycle." *Econometrica* 70.1 (2002): 47-89.

高頻度取引は金融危機時に市場に悪影響を与えるのか？ ～人工市場による一考察～

星野 真広^{1*} 山本 浩平² 水田 孝信³ 八木 勲²

Mahiro Hoshino¹, Kouhei Yamamoto², Takanobu Mizuta³, Isao Yagi²

¹ 神奈川工科大学大学院情報工学専攻

¹ Graduate School of Engineering, Department of Information and Computer Sciences,
Kanagawa Institute of Technology

² 神奈川工科大学情報学部工学科

² Department of Information and Computer Sciences, Faculty of Information Technology,
Kanagawa Institute of Technology

³ スパークス・アセット・マネジメント株式会社

³ SPARX Asset Management Co., Ltd.

Abstract: 金融市場安定時には高頻度取引（HFT）は市場に流動性を供給されている。しかし、金融危機等で市場が不安定になった際、彼らは注文の供給を手控えてしまい、それが市場不安定化に拍車をかけているのではないかという批判の声がある。そこで本研究では、HFT 戦略の中では一般的なマーケットメイク戦略をとる HFT が、市場急落時にどのような行動をし、それが市場にどのような影響を与えているのかを人工市場を用いて観察した。

1 はじめに

情報化社会の近年、金融市場においてコンピュータを利用し高速で取引をする高頻度取引 (High Frequency Trading, HFT) が注目を集めている。金融市場安定時には HFT は市場に流動性を供給されている。しかし、金融危機等で市場が不安定になった際、彼らは注文の供給を手控えてしまい、それが市場不安定化に拍車をかけているのではないかという批判の声がある。

この問題を議論するためには、現実の市場価格を操作して市場を不安定にし、そのときの HFT の挙動を観察しなければならないが、それは事実上不可能である。このような実証研究等の従来手法では議論が困難な課題を分析する方法の 1 つとして、人工市場を用いる方法がある。人工市場とは、コンピュータ上に仮想的に構築された金融市場マルチエージェントシステムである [Chiarella 09, Chen 12, Yeh 13]。人工市場では、エージェントにそれぞれ独自の売買手法を与え、それらを投資家として金融資産の取引をさせると、市場がどのような振る舞いをするかを確認することができる。

最近では人工市場を用いて市場の規制やルールが金融市場に与える本質的な影響を分析する研究が盛んに

行われている [松井 05, 八木 11, Yeh 13, Mizuta 15, Zhou 17, Nozaki 17, 米納 17, 丸山 19]。

そこで本研究では、HFT 戦略の中では一般的なマーケットメイク戦略をとる HFT が、市場急落時にどのような行動をし、それが市場にどのような影響を与えているのかを人工市場を用いて観察した。確認する項目は市場価格の推移、取引が成立した（約定した）注文板上のエージェント別注文数、HFT のポジションの 3 点である。

その結果、HFT の有無で市場価格の推移に大きな変化は見られなかった。また、価格が急落した後元の価格に収束するまでの期間に約定した注文板上の注文の発注主が HFT か否かを確認したところ、ほとんどが HFT ではないことがわかった。これにより、価格急落時において HFT は市場にほとんど影響を与えていないことがわかる。その際、HFT のポジションは市場価格につられて買いから売りに遷移したが、価格が安定するにつれて価格急落前のポジションに戻っていった。

2 人工市場モデル

本研究では Yagi et al. [Yagi 19] の人工市場モデルを基に、HFT エージェントとして草田ら [草田 15] のポジションマーケットメイカーを加えてモデルの構築を

*神奈川工科大学大学院情報工学専攻
〒 243-0292 神奈川県厚木市下荻野 1030
E-mail: s2085013@cce.kanagawa-it.ac.jp

行った。

本モデルでは、一つの資産のみを取引対象とする。一般投資家エージェントは n 体市場に参入し、一般投資家エージェント j は $j = 1$ から順に注文を出していく。そして $j = n$ まで注文を出し終えたあと $j = 1$ に戻る。ポジションマーケットメイカーは 1 体のみで、一般投資家エージェントが注文を行う前に売りと買いの注文両方を出す。

時刻 t は一般投資家エージェント 1 体が注文を出すたびに 1 だけ増える。注文をただけで取引が成立しない場合も時刻 t は 1 ステップ進む。ポジションマーケットメイカーの注文で時刻 t は進まない。

このモデルでの価格決定メカニズムは、買い手と売り手が価格を提示し、両者の提示価格が合致するとその価格での取引が成立するザラバ方式（連続ダブルオークション方式）とした。

2.1 一般投資家エージェント

一般投資家エージェントは、一般的な投資戦略に基づいて取引を行う投資家を想定したエージェントである。ファンダメンタル価格を参照し投資判断を行うファンダメンタル戦略、過去の価格推移を利用して投資行動を行うテクニカル戦略、試行錯誤的な投資判断を表すノイズ戦略からなる。また、市場状況の変化にあわせて学習することで、ファンダメンタル戦略とテクニカル戦略の比重を適宜切り替えていく。

以下に一般投資家エージェントの注文プロセスと学習プロセスを記す。一般投資家エージェントは以下の手順に従い、買いと売りの判断を行う。一般投資家エージェント j が時刻 t の時に予想する価格の変化率（予想リターン） r_{ej}^t は式 1 から求められる。

$$r_{ej}^t = \frac{1}{w_{1j}^t + w_{2j}^t + u_j} (w_{1j}^t r_{1j}^t + w_{2j}^t r_{2j}^t + u_j \epsilon_j^t) \quad (1)$$

ここで、 w_{ij}^t は時刻 t における一般投資家エージェント j の i 項目の重みであり、シミュレーション開始時にそれぞれ 0 から w_{imax} までの一様乱数で決める。右辺のカッコ内の 1 項目の w_{1j}^t はファンダメンタル戦略の成分の重み、2 項目の w_{2j}^t はテクニカル戦略の成分の重みである。これらは学習プロセスにて変化する。 u_j はノイズ戦略の成分の重みであり、シミュレーション開始時にそれぞれ 0 から u_{max} までの一様乱数で決められ、シミュレーション中は変化しない。これらの重みは互いに独立して変化する。これら 3 つの重みからくる影響は式 1 の右辺の最初の項にて正規化することで平準化している。

r_{ij}^t は時刻 t における一般投資家エージェント j の i 項目の予想リターンである。1 項目の r_{1j}^t はファンダ

メンタル成分のリターンであり、 $\ln(P_f/P^{t-1})$ とする。これは、ファンダメンタル価格と 1 期前の市場価格を比較し、市場価格の方が低ければ正、高ければ負の予想リターンを意味する。 P_f は時間で変化しない一定のファンダメンタル価格である。 P^t は時刻 t における市場価格（取引されなかった時刻では直近取引された価格であり、 $t = 0$ では $P^t = P_f$ とする）である。2 項目の r_{2j}^t はテクニカル成分の予想リターンであり、 $\ln(P^{t-1}/P^{t-1-\tau_j})$ とする。これは、過去のリターンが正なら正、負なら負の予想リターンを意味している。 τ_j は 1 から τ_{max} までの一様乱数でエージェントごとに決める。 ϵ_j^t は時刻 t におけるエージェント j のノイズ成分であり、平均 0、標準偏差 σ_ϵ の正規分布乱数である。

式 1 で導いた予想リターンを基に予想価格 P_{ej}^t を式 2 で求める。

$$P_{ej}^t = P^{t-1} \exp(r_{ej}^t) \quad (2)$$

注文価格 P_{oj}^t は $P_{ej}^t - P_d$ から $P_{ej}^t + P_d$ までの一様乱数で決める。そして、 P_{oj}^t が P_{ej}^t より小さければ、リスク資産 1 単位の買い注文を出し、 P_{oj}^t が P_{ej}^t より大ければ、リスク資産 1 単位の売り注文を出す。

学習はエージェントごとに注文の直前に行われ、各成分の予想リターン r_{ij}^t （ただし、 $i = 1, 2$ ）の符号の向きと学習期間のリターン $r_l^t = \ln(P^{t-1}/P^{t-1-t_l})$ の符号の向きとを比較し、 w_{ij}^t を式 3 のように書き換える。

同符号なら、

$$w_{ij}^t \leftarrow w_{ij}^t + k_l |r_l^t| q_j^t (w_{imax} - w_{ij}^t) \quad (3)$$

異符号なら、

$$w_{ij}^t \leftarrow w_{ij}^t - k_l |r_l^t| q_j^t w_{ij}^t$$

ここで、 k_l は定数、 q_j^t は時刻 t 、エージェント j に与えられる 0 から 1 までの一様乱数である。つまり、式 3 では、価格変化の方向の予測と現実の価格変化の方向が一致した戦略の重みを引き上げ、外れている戦略の重みを引き下げようとしている。また式 3 の学習プロセスとは別に、 w_{ij}^t を確率 δ_l で 0 から w_{imax} までの一様乱数にて再設定を行う。これは、これまでの投資戦略を抜本的に見直すために、試行錯誤的により良い戦略を模索している姿を、客観的にモデル化したものである。

2.2 HFT エージェント

HFT エージェントはポジションマーケットメイク戦略を取る。ポジションマーケットメイカーは自身のポジション（保有しているリスク資産数、買いなら正、空売りなら負）を考慮に入れ、最良買い気配値と最良売り気配値から注文基準価格を求め、この価格に、提示スプレッド θ_{pm} （1 取引あたりの期待利益率）を加えた

価格で売り注文を、減じた価格で買い注文を同時に出す [Nakajima 04, 草田 15]. 本エージェントは、草田ら [草田 15] のモデルに基づいて構築したが、彼らのモデルは 2 資産市場を考慮したモデルであったので、1 資産市場用に変更した。

時刻 t における取引市場の最良売り気配値 $P^{t,sell}$ 、最良買い気配値 $P^{t,buy}$ 、HFT エージェントの提示スプレッドを θ_{pm} 、時刻 t と $t+1$ の間に HFT エージェントが抱えるポジションを s_{pm}^t 、ポジション考慮度を w_{pm} とすると、買い注文価格 $P_{o,pm}^{t,buy}$ と売り注文価格 $P_{o,pm}^{t,sell}$ は式 4、式 5、式 6 で決定される。

$$P_{o,pm}^{t,buy} = P_{fv,pm}^t - \frac{1}{2}P_f\theta_{pm} \quad (4)$$

$$P_{o,pm}^{t,sell} = P_{fv,pm}^t + \frac{1}{2}P_f\theta_{pm} \quad (5)$$

$$P_{fv,pm}^t = \frac{P^{t,buy} + P^{t,sell}}{2} \left(1 - w_{pm} (s_{pm}^t)^3\right) \quad (6)$$

ここで、HFT エージェントの成行注文を防ぐため価格に制約を加える。その制約を式 7 に示す。

$$\begin{aligned} P_{o,pm}^{t,buy} &\geq P^{t,sell} \\ P_{o,pm}^{t,sell} &\leq P^{t,buy} \end{aligned} \quad (7)$$

これらの制約を満たすときの HFT エージェントの発注価格は式 8、式 9 のように設定する。これにより買い注文と売り注文の価格が逆転することも防ぐことができる。

$P_{o,pm}^{t,buy} \geq P^{t,sell}$ のとき、

$$\begin{aligned} P_{o,pm}^{t,buy} &= P^{t,sell} - \Delta P, \\ P_{o,pm}^{t,sell} &= (P^{t,sell} - \Delta P) + P_f \cdot \theta_{pm} \end{aligned} \quad (8)$$

$P_{o,pm}^{t,sell} \leq P^{t,buy}$ のとき、

$$\begin{aligned} P_{o,pm}^{t,buy} &= (P^{t,buy} + \Delta P) - P_f \cdot \theta_{pm}, \\ P_{o,pm}^{t,sell} &= P^{t,buy} + \Delta P \end{aligned} \quad (9)$$

3 実験

本実験では市場が不安定になった際の HFT エージェントのふるまいを確認したい。そのため、一般投資家エージェントに 300,001 期から 330,000 期にかけての 30,000 期の間、20% の確率で注文価格 1 の売り注文を出させる。これにより市場の価格は急落する。一般投資家エージェントが注文価格 1 の売り注文を発注する可能性のあるこの期間を誤発注期間とする。なお HFT エージェントは誤発注期間も通常通り注文を発注し続ける。この条件の下、HFT エージェントが参加してい




図 1: 市場価格推移の比較

表 1: 約定した注文板上の一般投資家エージェントと HFT エージェントの注文数の割合

		一般投資家 エージェント	HFT エージェント
誤発注期間前	買い注文	16.0%	84.0%
	売り注文	15.2%	84.8%
価格急落時	買い注文	98.4%	1.6%
	売り注文	2.1%	97.9%
リバウンド時	買い注文	17.7%	82.3%
	売り注文	93.8%	6.2%

る場合と非参加の場合の市場価格の推移、約定した注文板上のエージェント別注文数の割合、HFT エージェントのポジションの変化を確認する。

各パラメータの値は $n = 1000$, $w_{1max} = 1$, $w_{2max} = 10$, $u_{max} = 1$, $\tau_{max} = 10,000$, $\sigma_\epsilon = 0.06$, $P_d = 1,000$, $\Delta P = 1.0$, $P_f = 10,000.0$, $t_l = 10,000$, $t_c = 10,000$, $t_e = 1,000,000$, $k_l = 4.0$, $\delta_l = 0.01$, $w_{pm} = 0.00000005$, $\theta_{pm} = 0.003$ とする¹。 t_e はシミュレーション終了時の時刻である²。

4 結果と考察

4.1 市場価格の推移

HFT エージェントが参加している場合と非参加の場合の市場価格の推移を比べた場合、その違いに大きな変化は見られなかった (図 1 参照)。金融市場安定時に HFT エージェントが参加すると、HFT エージェントの注文スプレッド間で価格変動が安定し、市場のボラティリティは低下することがわかっている [星野 20]。しかし、今回の実験で価格が急落した際は、この作用が少ない、もしくは働いていないと言える。もし HFT エージェントのボラティリティ安定化作用が今回の価格

¹モデルの妥当性は実証研究 [Sewell 06, Cont 01] で得られている統計的性質 (Stylized fact) が満たされているかで判断した。

² $t_e = 1,000,000$ とした理由は、この値で実験の傾向を十分に把握することができ、期間を延ばしても傾向に差異は生じなかったからである。




図 2: 市場価格と HFT エージェントのポジション

急落時にも働くならばならば、HFT エージェントが参入している市場の価格の下落幅の方が、HFT エージェントが参入していない市場の価格の下落幅より低くなるはずである。今後この裏づけをとる予定である。

4.2 約定した注文板上のエージェント別注文数

誤発注前において、約定した注文板上の買い（売り）注文のうち、全体の 84.0 % (84.8 %) を HFT エージェントの注文が占めていた。誤発注期間では HFT エージェントの買い注文が 1.6%, 売り注文が 97.9% となり、誤発注期間前と比較し取引された HFT エージェントの買い注文の注文数が著しく低下した。リバウンド時では HFT エージェントの買い注文が 82.3%, 売り注文が 6.2% となり、誤発注期間前と比較し取引された HFT エージェントの売り注文の注文数が著しく低下した（表 1 参照）。

価格が急落している市場（価格急落時）では、その市場の板上に出されている買い注文が多く消費される。今回の結果ではそのほとんどが一般投資家エージェントの注文で賄われている。つまり、一般投資家エージェントの買い注文が取引された割合が 98.4% なのに対して、HFT エージェントの買い注文が取引された割合は 1.6% と限りなく小さく、HFT エージェントの取引は、市場価格の下落にはほとんど影響を与えないと判断していいだろう（表 1 価格急落時参照）。一方、リバウンド時では、その市場に出されている売り注文が多く消費される。こちらもそのほとんどが一般投資家エージェントの注文で賄われている。つまり、一般投資家エージェントの取引された売り注文の割合が 93.8% なのに対して、HFT エージェントの取引された売り注文の割合は 6.2% と小さく、HFT エージェントの取引は、市場価格の上昇にはほとんど影響を与えないと判断していいだろう（表 1 リバウンド時参照）。今後実験データからその裏づけを取る予定である。

4.3 HFT エージェントのポジション

HFT エージェントのポジションの変化は、市場価格が急落し始めると一旦は買いのポジションが多くなる。しかし価格急落中の中頃から売りのポジションに転じた。価格が底打ちすると売りポジションの増加も止まり、価格が元に戻るにつれて誤発注期間前の動きに戻っていった（図 2 参照）。

市場価格が急落し始めた際に買いのポジションが多くなるのは、誤発注期間中に一般投資家エージェントが発注する売り注文と HFT エージェントの買い注文が約定するためだと思われる。しかし、価格急落時の中頃より HFT エージェントは売りのポジションに転じる。この理由は、HFT エージェントの買いポジションが大きくなったため HFT エージェントの買い注文価格が低く設定されるようになり、代わって一般投資家エージェントの買い注文が最良買い気配値となったため、HFT エージェントの注文は約定されなくなったからだと考えられる。これは表 1 の価格急落時より、買い注文はほとんど約定していないことからわかる。

価格が元に戻るにつれて、次第に売りのポジションは減少し誤発注期間前のポジションの推移に戻っていった。表 1 のリバウンド時より、売り注文より買い注文の取引割合の方が多いことが確認できる。ポジションの推移が売り価格急落時よりなだらかなのは、価格急落時とリバウンド時の市場価格の推移の差が起因していると思われる。

5 まとめ

本実験では市場価格を急落させ、市場が不安定になった際の HFT のふるまいを、市場価格の推移、約定した注文板上のエージェント別注文数の割合、HFT エージェントのポジションの観点から確認を行った。その結果、HFT エージェントの有無で市場の価格推移に大きな変化は見られず、約定した注文板上のエージェント別注文数の割合の観点から HFT エージェントは市場に大きな影響を与えない可能性が確認できた。また HFT エージェントのポジションは、市場の価格推移につられてポジションが偏るが、再び価格推移が安定すると元の動きに戻ることが確認できた。

今回は実験結果から市場にどのような影響を与えているのかを観察した。しかし、なぜその結果が生じたかの裏づけを詳しくは行っていない。今後の課題としてはこれらの要因を調べることによってより詳しい議論ができるだろう。

留意事項

本論文はスパークス・アセット・マネジメント株式会社の公式見解を表すものではありません。すべては個人的見解であります。

参考文献

- [Chen 12] Chen, S.-H., Chang, C.-L., and Du, Y.-R.: Agent-based economic models and econometrics, *The Knowledge Engineering Review*, Vol. 27, No. 2, pp. 187–219 (2012)
- [Chiarella 09] Chiarella, C., Iori, G., and Perelló, J.: The impact of heterogeneous trading rules on the limit order book and order flows, *Journal of Economic Dynamics and Control*, Vol. 33, No. 3, pp. 525–537 (2009)
- [Cont 01] Cont, R.: Empirical properties of asset returns: stylized facts and statistical issues, *Quantitative Finance*, Vol. 1, pp. 223–236 (2001)
- [丸山 19] 丸山 隼矢, 水田 孝信, 八木 勲: 人工市場を用いた分散投資規制が市場に与える影響分析—ファンダメンタル価格急落時と急騰時における比較, 情報処理学会論文誌, Vol. 60, No. 10, pp. 1694–1703 (2019)
- [Mizuta 15] Mizuta, T., Izumi, K., Yagi, I., and Yoshimura, S.: Investigation of Price Variation Limits, Short Selling Regulation, and Uptick Rules and Their Optimal Design by Artificial Market Simulations, *Electronics and Communications in Japan*, Vol. 98, No. 7, pp. 13–21 (2015)
- [Nakajima 04] Nakajima, Y. and Shiozawa, Y.: Usefulness and feasibility of market maker in a thin market, in *the International Conference Experiments in Economic Sciences: New Approaches to Solving Real-world Problems*, pp. 1000–1003 (2004), <https://www.cc.kyoto-su.ac.jp/project/orc/execo/EES2004/proceedings.html>
- [Nozaki 17] Nozaki, T., Mizuta, T., and Yagi, I.: A Study on the Market Impact of the Rule for Investment Diversification at the Time of a Market Crash Using a Multi-Agent Simulation, *IEICE Transactions on Information and Systems*, Vol. E100.D, No. 12, pp. 2878–2887 (2017)
- [Sewell 06] Sewell, M.: Characterization of financial time series (2006)
- [八木 11] 八木 勲, 水田 孝信, 和泉 潔: 人工市場を利用した空売り規制が与える株式市場への影響分析, 人工知能学会論文誌, Vol. 26, No. 1, pp. 208–216 (2011)
- [Yagi 19] Yagi, I., Masuda, Y., and Mizuta, T.: Detection of Factors Influencing Market Liquidity Using an Agent-Based Simulation, in *Network Theory and Agent-Based Modeling in Economics and Finance*, pp. 111–131, Springer (2019)
- [Yeh 13] Yeh, C.-H. and Yang, C.-Y.: Do price limits hurt the market?, *Journal of Economic Interaction and Coordination*, Vol. 8, No. 1, pp. 125–153 (2013)
- [Zhou 17] Zhou, X. and Li, H.: Buying on Margin and Short Selling in an Artificial Double Auction Market, *Computational Economics* (2017)
- [松井 05] 松井 宏樹, 東条 敏: 人工市場アプローチによる介入エージェントを用いた為替介入効果の分析, 人工知能学会論文誌, Vol. 20, No. 1, pp. 36–45 (2005)
- [星野 20] 星野 真広, 水田 孝信, 八木 勲: 人工市場を用いた負の売買手数料(リベート)が株式市場に与える影響の調査, 人工知能学会全国大会論文集, Vol. JSAI2020, pp. 2L5GS1304–2L5GS1304 (2020)
- [草田 15] 草田 裕紀, 水田 孝信, 早川 聡, 和泉 潔: 保有資産を考慮したマーケットメイク戦略が取引所間競争に与える影響: 人工市場アプローチによる分析, 人工知能学会論文誌, Vol. 30, No. 5, pp. 675–682 (2015)
- [米納 17] 米納 弘渡, 和泉 潔: リスク管理が市場リスクをもたらすか: 高頻度・大規模な人工市場シミュレーション, 研究報告知能システム (ICS), Vol. 2017-ICS-186, No. 4, pp. 1–6 (2017)

自発的に市場規模が定まる金融取引モデル

Self-organization of market sizing in financial transaction model

片平啓^{1*} 陳昱² 秋山英三¹
Kei Katahira¹ Yu Chen² Eizo Akiyama¹

¹ 筑波大学システム情報系

¹ Faculty of Engineering, Information and Systems, University of Tsukuba

² 東京大学大学院新領域創成科学研究科

² Graduate School of Frontier Sciences, The University of Tokyo

Abstract: Various preceding market models can reproduce basic financial stylized facts such as volatility clustering, but most of those models require ad hoc tuning of parameters for the reproduction. Inspired by the idea of the sandpile model, we present a simple agent-based model of the financial market named Self-organized Speculation Game, where the number of traders is spontaneously tuned. While this model has high reproducibility of stylized facts, it holds similar behavioral properties to those of the sandpile model. The simulation results infer the possible contribution of self-organized criticality for the *spontaneous* emergence of stylized facts.

1 はじめに

金融資産における価格リターンの時系列データには、stylized facts と総称されるいくつかの定量・定性的な性質が存在する。たとえば、ボラティリティの大きい箇所が時間的にまとまって現れる、ボラティリティ・クラスタリングと呼ばれる基本特性はよく知られている。Cont の報告 [1] によれば、ボラティリティ・クラスタリングを含め、少なくとも 11 個の統計性質が確認されている。

ボラティリティ・クラスタリングなどの基本的な stylized facts の創発メカニズムは、シンプルなエージェント・ベース・モデルを活用する経済物理学研究の進展により、大分明らかになってきている。最も支持されているメカニズムの 1 つが、少数派ゲーム [2] の派生市場モデル類を中心に議論された、他人の行動に同調する群衆行動である [3]。一方で、オーダーブックによる価格形成システムそのものも、ボラティリティのクラスター化に資することも、Maslov モデル [4] によって示されている。さらに片平・陳は、投機ゲーム [5] による最新の研究成果として、往復売買取引におけるホールド期間の多様性が、ボラティリティの増大に寄与するという新規メカニズムも提案している [6]。

しかしながら、基本的に自由放任主義の金融市場で、なぜ自然に stylized facts の出現にまで至るのか、その

自発性については、依然としてほとんど分かっていない。Stylized facts は、市場の種類やその歴史の長さ、制度の違いなどに依存せず、共通して観察される普遍的な現象である。たとえば、100 年以上の歴史を持つアメリカの成熟市場においても、高々 30 年程度の中国の新興市場においても、同様の特徴的性質が観測されている。よって、市場には何らかの自発的な調整原理が働いている可能性があり、モデルとして考えるならば、外部からの調整が必要なパラメータ数はごく少数に限られるはずである。しかし、ほとんどの先行市場モデルでは、stylized facts を再現するためには、シミュレーションの開始前に、人為的にすべてのパラメータの値を調整しなければならない。

この問題に対しては、stylized facts を臨界現象として捉えることが、1 つの有効なアプローチになるように思われる。Stylized facts の中には、価格リターンの累積分布やボラティリティの自己相関に冪乗則が見られる¹という基本特性も含まれる [1]。冪乗則と臨界現象には密接な関係があることから、経済物理学では、市場システムが臨界に近い状態にあるのではないかと考えられている [8]。

一方、物理学では、外部からの調整が無くても自然に臨界まで到達する、自己組織化臨界と呼ばれる原理が、砂山モデル [9] により提示されている。このモデルでは、毎時間ステップに 1 粒の砂が、ランダムに選ばれた $L \times L$ の格子上的 1 マスに落ちる。各マスには次

*連絡先：筑波大学システム情報系
〒305-8573 茨城県つくば市天王台 1-1-1
E-mail: k.katahira@akiyama-lab.net

¹ ボラティリティの長期自己相関については、対数関数の方がフィッティングが良いという研究結果もある [7]。

第に砂が蓄積されていくが、閾値 4 に達すると山が崩れ、上下左右の隣接マスに砂が流れる。移動した砂によって山崩れが連鎖的に続発すると、大きな砂雪崩が起きる。なお、雪崩により砂が格子端まで達した場合には、その砂は落ちて消える。ルールはこのように単純であるが、砂山モデルのシステムは自発的に臨界へ至り、雪崩の規模とその頻度の間に冪乗則が現れる。

そこで、本研究では、stylized facts の自発性について調べるため、自己組織化臨界の原理を投機ゲーム [5] に導入し、一部のパラメータが自然に調整されるシンプルな金融市場のエージェント・ベース・モデルの構築を試みる。具体的には、stylized facts の再現能力を有しながら、市場に参加するプレイヤー数が時間発展的に調整される Self-organized Speculation Game (SOSG) を、砂山モデルの仕組みを参考にして構築する。

2 SOSG

SOSG は、少数派ゲーム [2] の仕組みを応用して考案した投機ゲームに、ゆっくりと 1 粒ずつ砂を落とす砂山モデル [9] の仕組みを取り入れ、市場規模が自発的に定まるように改良を施したモデルである。買いと売りを 1 セットとした単一ポジション²の往復取引や保有資本に基づいた複数量注文、現実的世界と認知的世界の相互投影³といった投機ゲームの特徴的構造に変わりはないが、SOSG では、stylized facts を再現するために調整が必要なパラメータの数が 3 つに減っている。

ゲームの開始時、SOSG のゲーム市場には、誰もいない。毎時間ステップ t のはじめに、初期資本 $w_i(t) = 10B$ (B は定数) とランダムに決めた戦略 (後述) 1 つを与えられたプレイヤー i が 1 人参入する。

その後、ゲーム市場に参加している $N(t)$ 人それぞれが、買い (= 1) と売り (= -1) と待機 (= 0) の中から、行動 $a_i(t)$ として 1 つ選ぶ。プレイヤーが買い、または売り (空売りも可能) の注文を出す場合、注文量 $q_i(t)$ は、床関数 $\lfloor \dots \rfloor$ を用いて、次のように決める：

$$q_i(t) = \lfloor \frac{w_i(t)}{B} \rfloor. \quad (1)$$

取引単位量 B は、複数量注文のしやすさを調整するパラメータである。ただし、往復取引の始めと終わりの注文量は同じとする。また、買い (売り) ポジションの保有時に買い増し (売り増し) はできない。

市場価格の変動 Δp は、買い注文と売り注文の需給関係で決まるとする。具体的には、次のように [10] の

注文不均衡式を適用する：

$$\Delta p = p(t) - p(t-1) = \frac{1}{N(t)} \sum_{j=1}^{N(t)} a_j(t) q_j(t). \quad (2)$$

式 2 のような注文不均衡式を用いる場合、超過需要側の注文の約定を常に保証するため、十分な流動性を提供するマーケットメーカーの存在を暗黙に仮定している。

各プレイヤーは、行動の選択にあたり、離散価格変動 $h(t)$ の列により構成される 5 進数の履歴 $H(t)$ を参照する。離散価格変動 $h(t)$ は、 Δp から以下のように決める：

$$h(t) = \begin{cases} 2 \text{ (大きく上昇)} & \text{if } \Delta p > C, \\ 1 \text{ (上昇)} & \text{if } C \geq \Delta p > 0, \\ 0 \text{ (変化なし)} & \text{if } \Delta p = 0, \\ -1 \text{ (下落)} & \text{if } -C \leq \Delta p < 0, \\ -2 \text{ (大きく下落)} & \text{if } \Delta p < -C. \end{cases} \quad (3)$$

ここで、 C は認知閾と呼ぶパラメータであり、大きな価格変動とプレイヤーが認識する境界値を表す。式 3 より、履歴は、価格変動の方向の情報だけでなく、粗いながら、大きさの情報も有する。

実価格 $p(t)$ の変動とは別に、この履歴の情報の粗さを考慮して「プレイヤーが認知する価格変動」、つまり「認知価格 $P(t)$ 」の変動が次の式に従って起こるとする：

$$P(t) = P(t-1) + h(t). \quad (4)$$

ある往復取引がどの程度良いものだったのかは、取引前後の認知価格 $P(t)$ の変化に基づいて評価される。

記憶長 M のプレイヤーは、履歴から直近 M 時間ステップ分の変動パターンを読み取る。そして、自分の戦略に従い、その変動パターンに対応する推奨行動 $a_i(t)$ を選択する (表 1 を参照)。ただし、単一ポジションの往復取引を実現するため、取引の開始ポジションと同じ行動を戦略が推奨する場合には、代わりに待機を選択する。

反対売買により往復取引を終える際は、人間が情報を単純化して扱う様子を表現した認知的世界において、まず、認知的利得 $\Pi_i(t)$ ⁴ を算出する。プレイヤーがポジションを t_0 に開き、 t に閉じる場合、この往復取引における単位量あたりの認知的利得は、式 4 の認知価格を用いて、次のように求められる：

$$\begin{aligned} \Pi_i(t) &= a_i(t_0)(P(t) - P(t_0)) \\ &= a_i(t_0) \sum_{k=t_0+1}^t h(k). \end{aligned} \quad (5)$$

²両建てはできない。

³2 つの世界を行き来して進行する投機ゲームの枠組みについては、[5] の Fig.1 を参照。

⁴ $\Pi_i(t)$ は、投機ゲームにおける戦略利得 $\Delta G_i(t)$ と同義である。

表 1: $M = 3$ のときの戦略例.

履歴			推奨行動
-2	-2	-2	1
-2	-2	-1	0
-2	-2	0	0
-2	-2	1	-1
-2	-2	2	1
-2	-1	-2	0
	\vdots		\vdots
2	2	2	-1

さらに、認知的世界から現実的世界に戻って資本 $w_i(t)$ を更新するため、注文量 $q_i(t)$ を考慮して $\Pi_i(t)$ を単調増加な関数 f で変換し、資本調整 $\Delta w_i(t)$ を求める：

$$\begin{aligned} w_i(t) &= w_i(t_0) + \Delta w_i(t) \\ &= w_i(t_0) + f(\Pi_i(t)q_i(t_0)). \end{aligned} \quad (6)$$

本稿では、複雑化を避けるため、 $\Delta w_i(t) = \Pi_i(t)q_i(t_0)$ とする。また、資本更新の結果、 $w_i(t) < B$ となり、1 単位も注文できない状態に陥る場合には、そのプレイヤーはゲーム市場から退出する。

なお、式 6 の $\Delta w_i(t)$ は、市場価格 $p(t)$ から直接計算した場合の資本調整量と異なるが、この差は外部調整されるものとする。つまり、SOSG では、自分のすべての投資資本をプレイヤー自身で賄うというセルフファイナンスの仮定を置かない。

以上が SOSG の仕組みである。砂山モデルと改めて対比すると、1 人ずつ参入するプレイヤーが 1 粒ずつ落下する砂に、プレイヤーの参入先であるゲーム市場が砂粒の落下先である格子にそれぞれ対応している。また、本モデルの主要パラメータは、記憶長 M と取引単位量 B と認知閾 C の 3 つであるが、本研究のシミュレーションでは、 $M = 5$ と $C = 3$ に固定し、 B のみを変化させる。なお、市場価格 $p(t)$ の初期値は任意で構わないが、リターン $r(t) = \ln p(t) - \ln p(t-1)$ を計算するため、 $p(0) = 100$ ($\gg 1$) とする。

3 結果・考察

はじめに、SOSG では、自発的に市場規模が定まり、かつ同時に、stylized facts も再現もされることを示す。図 1 の (a) と (b) は、 $B = 9$ としたときのゲーム市場に参加しているプレイヤー数、ならびに対応する市場価格のリターン $r(t)$ の時系列をそれぞれプロットしたものである。図 1 の (a) からは、シミュレーションのはじめに 700 人程度まで線形的に増加した後は、その

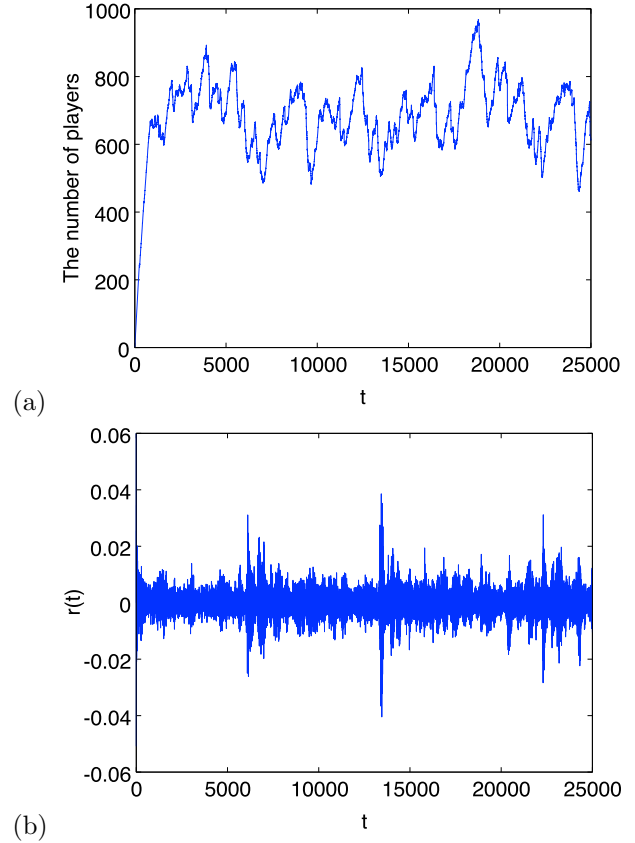



図 1: (a) ゲーム市場に残留するプレイヤー数と (b) 対応するリターンの推移 ($B = 9$).


周辺値でプレイヤー数が揺らいでおり、時間の経過に伴って市場規模が自然に調整されている様子が見て取れる。また、対応する図 1 の (b) の価格リターンにおいても、間欠的にボラティリティがまとまりながら増大しており、安定してボラティリティ・クラスタリングも創発していることが分かる。

なお、SOSG の stylized facts の再現能力は、元の投機ゲーム [5] と同じであり、同一のパラメータ下において、10 個の stylized facts を再現することができる。また、[6] で明らかにした、ボラティリティ・クラスタリングの創発メカニズムや各パラメータの効果についても、SOSG では維持されている。さらに、投機家以外の影響を考慮して、価格変動に摂動を加えた場合のシミュレーション結果も、SOSG は [11] と同様である。

続いて、砂山モデルと SOSG の振る舞いの類似性を示す。まず、双方のモデルとも、最終的なシステムサイズが 1 つのパラメータによって大きく決定づけられ、系の調整に必要な時間もその大きさと正に相関するという特徴がある。砂山モデルでは、図 2 の (a) に示すように、格子内に残っている砂の総量が、格子の 1 辺の長さ L に強く依存する。 L が大きいほど、残存する砂粒の数が増え、値が安定するまでにより多くの時間



(a)



(b)

図 2: (a) L を変えたときの砂山モデルの格子に残存する砂の量と (b) B を変えたときの SOSG のゲーム市場に残留するプレイヤー数の推移。

を要する。SOSG においても同様に、ゲーム市場内に留まるプレイヤーの数が、取引単位量 B に強く依存する。図 2 の (b) に示すように、 B が大きくなるほど、市場規模が拡大し、収束までの時間も長くなる。ただし、一度に格子から流出する砂の量よりも、一度にゲーム市場から退出するプレイヤーの数の方が相対的に多いため、安定状態における揺らぎは、砂山モデルよりも SOSG の方が少し大きい。

加えて、砂山モデルにおける雪崩の規模と頻度の関係のように、SOSG でも価格リターンの累積分布に冪乗則が観察される。図 3 の青線は、52,000 時間ステップ（内 2,000 時間ステップは移行期間）のシミュレーションを 20 回行ってプロットした $B = 9$ ときの正の $r(t)$ の累積分布である。この図は、Clauset らが考案した冪乗則の頑健な検定方法 [12] を取り入れた Python パッケージ [13] によって作成している。赤の点線は、推定されたテールインデックス $\alpha = 4.56$ の冪分布関数であり、青線の累積分布に対し、推定された緑の点線の指数分布関数よりもフィッティングが良いことが分かる。また、Clauset ら提案の p 値による定量的判定においても $p = 4.05 \times 10^{-4} (< 0.1)$ となって有意であり、




図 3: $B = 9$ のときのリターン（20 試行回から生成した 500,195 個の正のデータ）の累積分布。

冪分布の方が真の分布に近いと結論付けられる。

このように、システムサイズの調整の様子や冪乗則の出現において、SOSG は砂山モデルと類似しており、自己組織化臨界の原理が SOSG でもうまく機能していると考えられる。また、それでありながら、図 1 の (b) でも示したように、SOSG は、金融市場のモデルとして、ボラティリティ・クラスタリングなどの stylized facts を再現することが可能である。これらの結果は、自己組織化臨界の働きによって、stylized facts が自然に発生している可能性を示している。

4 むすび

本研究では、投機ゲームに自己組織化臨界の原理を取り入れることで、プレイヤー数の人為的な制御を必要としないシンプルな金融市場のエージェント・ベース・モデル「SOSG」を構築した。主要パラメータの数が減っているのにも関わらず、SOSG は、投機ゲームと同水準の stylized facts の再現能力を維持している。したがって、SOSG は、投機ゲームをスリムにしたより本質的なモデルであると言えよう。また、SOSG は、参考にした砂山モデルと共通する性質を持っており、市場規模が自己調整されたり、価格リターンに冪乗則が現れたりする。このような SOSG のシミュレーション結果は、現実市場における stylized facts の自発的創発に関して、自己組織化臨界のメカニズムの存在や寄与の可能性を示唆するものと考えられる。

謝辞

本研究は、JSPS 科研費 JP17J09156, JP20J00107 の助成を受けたものです。

参考文献

- [1] Cont, R. (2001). Empirical properties of asset returns: stylized facts and statistical issues.
- [2] Challet, D., & Zhang, Y. C. (1997). Emergence of cooperation and organization in an evolutionary game. *Physica A: Statistical Mechanics and its Applications*, 246(3-4), 407-418.
- [3] Challet, D., Marsili, M., & Zhang, Y. C. (2001). Stylized facts of financial markets and market crashes in minority games. *Physica A: Statistical Mechanics and its Applications*, 294(3-4), 514-524.
- [4] Maslov, S. (2000). Simple model of a limit order-driven market. *Physica A: Statistical Mechanics and its Applications*, 278(3-4), 571-578.
- [5] Katahira, K., Chen, Y., Hashimoto, G., & Okuda, H. (2019). Development of an agent-based speculation game for higher reproducibility of financial stylized facts. *Physica A: Statistical Mechanics and its Applications*, 524, 503-518.
- [6] Katahira, K., & Chen, Y. Heterogeneous Round-trip Trading and the Emergence of Volatility Clustering in Speculation Game, *Journal of Systems Science and Complexity* (under review).
- [7] Zumbach, G. O. (2007). The riskmetrics 2006 methodology. Available at SSRN 1420185.
- [8] Mantegna, R. N., & Stanley, H. E. (1999). *Introduction to econophysics: correlations and complexity in finance*. Cambridge university press.
- [9] Bak, P., Tang, C., & Wiesenfeld, K. (1987). Self-organized criticality: An explanation of the 1/f noise. *Physical review letters*, 59(4), 381.
- [10] Bouchaud, J. P., & Cont, R. (2000). Herd behaviour and aggregate fluctuations in financial market. *Macroeconomic Dynamics*, 2, 170-196.
- [11] Katahira, K., & Chen, Y. (2020). An extended Speculation Game for the recovery of Hurst exponent of financial time series. *New Mathematics and Natural Computation*, 16(02), 319-325.
- [12] Clauset, A., Shalizi, C. R., & Newman, M. E. (2009). Power-law distributions in empirical data. *SIAM review*, 51(4), 661-703.
- [13] Alstott, J., Bullmore, E., & Plenz, D. (2014). powerlaw: a Python package for analysis of heavy-tailed distributions. *PloS one*, 9(1), e85777.

タグに基づくデータ拡張と因果文抽出を用いた市況コメント生成の試み

An Attempt to Generate Market Comments via Causal Extraction and Data Expansion Based on Tags

坂地泰紀^{1*} 近藤洋平² 和泉潔¹

長尾慎太郎² 加藤惇雄³

Hiroki Sakaji¹ Yohei Kondo¹ Izumi Kiyoshi¹

Shintaro Nagao¹ Atsuo Kato¹

¹ 東京大学

¹ The University of Tokyo

² 大和アセットマネジメント

² Daiwa Asset Management

³ 大和総研

³ Daiwa Institute of Research

Abstract: 資産運用会社や証券会社などの多くの金融機関では、定期的な（月次、週次等）市況コメントを作成し、顧客に提供している。この市況コメントを作成する際には、ニュース記事や公的機関発表の統計など、様々な情報源にあたり事実関係を確認しながら、実務者の知識や経験に照らして原稿を作成することになる。一方で、こうした市況コメントの調査・執筆の作業は時間とコストが伴うものである。もし、主要な情報源から、自然言語処理をはじめとした機械的なプロセスによって、信頼できる市況コメントを作成することができれば、それは金融機関における当該業務のコストの削減、あるいは処理の迅速化やカバレッジ拡大による顧客サービス向上に資することになる。そこで、本研究では、まずニュース記事に含まれる原因・結果を含む因果文を抽出することで、市況コメントを自動的に生成することを試みた。

1 はじめに

資産運用会社や証券会社などの多くの金融機関では、定期的な（月次、週次等）市況コメントを作成し、顧客に提供している。この市況コメントを作成する際には、ニュース記事や公的機関発表の統計など、様々な情報源にあたり事実関係を確認しながら、実務者の知識や経験に照らして原稿を作成することになる。例えば、大和アセットマネジメントが公開している2020年9月の投資環境見通しにおける米株への市況コメントでは、「前回、見通しをやや弱気に引き下げたものの、前回比でS&P500指数は5%弱の上昇と底堅く推移。新型コロナウイルスの感染拡大は継続も、追加経済対策への期待や新型コロナウイルスワクチンへの期待などが株価を支えた。」¹など、現在の推移と、その原因に

ついて言及しているコメントを作成し、公開している。米国の他にも、ユーロ圏、日本、カナダ、中国、ブラジルなどについてのコメントも記載されている。

一方で、こうした市況コメントの調査・執筆の作業は時間とコストが伴うものである。上記で示した通り、米国だけではなく、カナダや中国などの国について作成する際にも、それぞれの国の株価動向や経済状況などを新聞記事などの情報源から調べ、コメントを生成する必要がある。また、米国や日本などの主要経済国の情報は数多くあるのに対して、ブラジルやインドなどの新興国の情報はそれらに比べて多くはなく、調べるのも難しくなってくる。

もし、主要な情報源から、自然言語処理をはじめとした機械的なプロセスによって、信頼できる市況コメントを作成することができれば、それは金融機関における当該業務のコストの削減、あるいは処理の迅速化やカバレッジ拡大による顧客サービス向上に資することになる。特に、ブラジルやインドなどの新興国の情

*連絡先：東京大学大学院工学系研究科
〒113-8656 東京都文京区本郷7-3-1
E-mail: sakaji@sys.t.u-tokyo.ac.jp

¹https://www.daiwa-am.co.jp/specialreport/outlook/monthly_report_202009.pdf

報を自動的に集めることができれば、今まで少ない情報を集めていた作業は大幅に削減される。

市況コメントを生成するにあたり、上記の例で示したように市況コメントには、変動の要因を記述することが多い。これは、事前の調査で、作成者が情報源を調べるにあたり、原因とその結果が記述された文を参考にしている場合が多いということからも、着目すべき点である。そこで、本研究では、まずニュース記事に含まれる原因・結果を含む因果文を抽出することで、市況コメントを自動的に生成することを試みる。

2 関連研究

関連研究としては、酒井らの研究 [酒井 19][酒井 20] が挙げられる。酒井らは日経新聞記事を用いて、国内株式市場 (日経平均) について月ごとに市況コメントを生成する手法を提案している。彼らは、まず、日経新聞記事から日経平均が大幅に変動したことが記述されている記事のみを抽出し、そこからブーストラップ法に基づいた要因文抽出により、各月の市況コメントを生成している。また、最新の研究発表 [酒井 20] では、doc2vec と因果チェーンによる補完情報を用いることで、生成する市況コメントの質を高めている。それに対して、本研究では、新聞記事に付与されているタグに着目し、日本だけではなく、様々な国の市況コメントを生成できるようなフレームワークを構築している。

また、Murakami et al.[Murakami 17] は日経平均株価の時系列データを入力として、その値動きを用いて市況コメントを生成する手法を提案している。Murakami et al. は、ある短い期間の日経平均株価の値動きから市況コメントを生成しているのに対して、本研究では新聞記事から月ごとの市況コメントを生成しようとしており、タスクが異なる。また、彼らは値動きのみを伝える市況コメントを生成しようとしているのに対して、本研究では因果関係に着目し、値動きの原因を含む形で市況コメントを生成しようとしている点も異なる。

3 提案手法

本研究では、以下のステップに従って市況コメントを自動的に生成する。

Step 1: タグに基づき各国の市況に関連する新聞記事 (関連記事) を抽出する。

Step 2: また、Step 1 で抽出した記事を正例にして、機械学習を用いて関連記事を抽出する。

Step 3: Step 1 と Step 2 で抽出した関連記事から因果文を機械学習を用いて抽出する。

Step 4: 過去の市況コメントを用いて、日次のリターン予測を行う機械学習モデルを学習する。

Step 5: Step 3 で抽出した因果文と、Step 4 で学習したモデルを用いて、各文にスコアを付与する。その後、スコアの高い文を市況コメントとして抽出する。□

ここで、Step 1 で二つのタグを用いる。インド市況に関しては「RR:1122」を、南アフリカ市況に関しては「RR:1163」を用いる。Step 2 では BERT を用いて関連記事を抽出する。Step 3 の機械学習には、Logistic Regression, Random Forest, SVM, LSTM, LSTM Attention と BERT を試し、最も性能良いものを採用する。Step 4 では、機械学習に Random Forest を用いた。また、Step 5 では、因果文抽出時の尤度と、Step 4 で作成したモデルを用いてリターンの方向性を予測したときの尤度を掛け合わせたものをスコアとして、これに基づいて文をランキングする。

4 評価実験

本節では、2 つの実験と、市況コメント生成の試みについて述べる。まず一つ目の実験として、因果文の抽出について行った。因果文抽出にはいくつかの手法 [Mirza 14][Dasgupta 18] が提案されているが、どの手法が良いか確認するためにロイターニュース記事 (英語) と Semeval2010 Task8 のデータに対して実験を行い、その性能を評価する。ロイターニュース記事は、2,339 文 (うち 738 文が因果あり) のデータを学習 7, 検証 1, テスト 2 に分割し利用する。Semeval2010 Task8 は文に含まれる単語間の関係を予測するタスクであり、その関係の一つに原因・結果がある。ここでは、それを正例とし、残りを負例として扱う。Semeval も 10,717 文のデータ (うち 1,331 文が因果あり) を学習 7, 検証 1, テスト 2 に分割し利用する。

二つ目は、日次の市況コメントを入手し、その日の終値に基づいた各国の株式リターンの方向性を予測するものである。日次の市況コメントについては、大和アセットマネジメント様に提供頂いた。市況コメントの中には、因果文であるもののため、全てを使った場合と因果文だけを利用した場合の二通りで実験を行う。因果文の抽出は、前の実験で最もよかったモデルを利用する。これにより、リターンに対する因果文の説明力を確認する。対象とする国は、インドと南アフリカである。インドに関しては、2001 年 9 月 3 日より 2019 年 11 月 29 日までの 4596 件のデータ (うち 4,165 文が因果あり) となっている。南アフリカに関しては、2001 年 9 月 3 日より 2019 年 11 月 29 日までの 4596 件のデータ (うち 3,579 文が因果あり) となっている。デー

表 1: ロイターニュース記事を対象にした因果文抽出結果

	Accuracy	Precision	Recall	F1
Logistic Regression	0.853	0.838	0.825	0.831
Random Forest	0.817	0.829	0.748	0.769
SVM[Mirza 14]	0.813	0.790	0.785	0.787
LSTM[Dasgupta 18]	0.659	0.612	0.608	0.610
LSTM Attention	0.771	0.747	0.768	0.753
BERT	0.877	0.858	0.844	0.866

表 2: Semeval2010 Task8 を対象にした因果文抽出結果

	Accuracy	Precision	Recall	F1
Logistic Regression	0.955	0.899	0.888	0.894
Random Forest	0.945	0.945	0.787	0.844
SVM[Mirza 14]	0.949	0.879	0.880	0.880
LSTM[Dasgupta 18]	0.919	0.801	0.861	0.827
LSTM Attention	0.942	0.873	0.846	0.859
BERT	0.967	0.922	0.922	0.922

タ数が異なるのは、市況コメントがない日が存在するためである。

表 3: 市況コメントを用いた日次リターンの方向予測

	Accuracy	Precision	Recall	F1
インド	0.873	0.876	0.870	0.872
インド (因)	0.893	0.894	0.891	0.892
南ア	0.764	0.765	0.764	0.764
南ア (因)	0.773	0.781	0.773	0.771

5 結果と考察

表 1 にロイターニュース記事を対象にした因果文抽出の結果を示し、表 2 に Semeval2010 task8 を対象にした因果文抽出の結果を示す。表 3 に市況コメントを用いたリターンの方向性予測の結果を示す。表 4 と表 5 には、実際に生成した市況コメントの例を示す。

表 1 と表 2 より、因果文抽出に関しては、BERT が最も良い結果となった。そのため、リターンの方向性予測では BERT を用いて実験を行った。表 3 より、因果文に絞ることで、その性能は向上している。このことから、因果文がリターンの方向性予測に対して、説明力が高いことを示唆しており、本提案手法の妥当性を示している。表 4 と表 5 より、インド市場や南アフリカ市場に関連した文を市況コメントとして抽出することができた。今後は、この生成した市況コメントを評価していく。

表 4: インドにおける市況コメント生成例

Indian shares fell on Thursday, dragged by technology stocks, after Infosys Ltd's revenue outlook and plan to return cash to shareholders fell short of expectations, raising concerns at the start of the earnings reporting season.
Indian shares rose on Monday, on track for their second consecutive session of gains, as blue-chips rose after forecast of a timely monsoon raised hopes the central bank would lower interest rates in June.
India's fuel demand rose 6.4 percent in November compared with the same month last year, driven by higher sales of gasoline as discounts and festive season buying boosted passenger vehicle sales.

6 まとめ

本研究では、ニュース記事に含まれる原因・結果を含む因果文を抽出することで、市況コメントを自動的に生成することを試みた。BERT により、高精度に因果文を抽出できることを示した。因果文を用いる妥当性として、実験によって、因果文が各国の株式市場リターンの説明力が高いことを示した。リターン予測を行う機械学習と因果文を用いることで、市況コメントの抽出を試みた。今後は、抽出した市況コメントをどのように評価するかを定め、その性能評価を行う。

表 5: 南アフリカにおける市況コメント生成例

South Africa's equities market slid on Monday, falling more than 2 percent on the first day of trade in 2016 in the wake of a sharp decline in Asian assets after data showed a contraction in Chinese factory activity.

South African shares were led higher by the mining sector on Friday and the market looked set to make further gains in coming sessions after the government slashed fuel prices.

South African retailers have struggled to lift earnings as consumers face increasing pressures on disposable income.

参考文献

- [Dasgupta 18] Dasgupta, T., Saha, R., Dey, L., and Naskar, A.: Automatic extraction of causal relations from text using linguistically informed deep neural networks, in *Proceedings of the 19th Annual SIGdial Meeting on Discourse and Dialogue*, pp. 306–316 (2018)
- [Mirza 14] Mirza, P. and Tonelli, S.: An Analysis of Causality between Events and its Relation to Temporal Information, in *Proceedings of COLING 2014, the 25th International Conference on Computational Linguistics*, pp. 2097–2106 (2014)
- [Murakami 17] Murakami, S., Watanabe, A., Miyazawa, A., Goshima, K., Yanase, T., Takamura, H., and Miyao, Y.: Learning to generate market comments from stock prices, in *Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics*, pp. 1374–1384 (2017)
- [酒井 19] 酒井 浩之, 坂地 泰紀, 和泉 潔, 松井 藤五郎, 入江 圭太郎: 関連記事を用いた市況分析コメントの自動生成, 人工知能学会第 22 回金融情報学研究会, pp. 61–66 (2019)
- [酒井 20] 酒井 浩之, 坂地 泰紀, 和泉 潔, 松井 藤五郎, 入江 圭太郎: 学習データ自動生成による市況分析コメント作成のための要因文と補完情報の抽出, 2020 年度人工知能学会全国大会 (2020)

債券市場における金融極性辞書の自動構築

Automatic Construction of Financial Sentiment Lexicons on Bond

今井 康太¹ 酒井 浩之¹ 高野 海斗¹ 北島 良三²
末廣 徹³ 稲垣 真太郎³ 木村 柚里³

Kota Imai¹, Hiroyuki Sakai¹, Kaito Takano¹, Ryoza Kitajima²
Toru Suehiro³, Shintaro Inagaki³, Yuri Kimura³

¹成蹊大学

¹Seikei University

²東京工芸大学

²Tokyo Polytechnic University

³みずほ証券株式会社

³Mizuho Securities Co., Ltd.

Abstract: 本研究では、金融テキストを用いて、債券市場における金融極性辞書を構築するための表現獲得、および極性付与手法を提案する。獲得する語句は、各金融市場において特徴的な語やそれらを表現にまで拡張した文字列である。例えば、「増加」という語について、その語のみでは極性を決定できず、「消費が増加」や「リスクが増加」のように語の前後関係まで広く捉えることで極性が付与できる。我々はこれまで株式を対象として表現獲得、および、極性付与のための手法[1]を開発しており、良好な精度を得た。しかし、債券を対象として表現獲得、および、極性付与を行う場合、高い精度を達成できなかった。債券における表現への極性付与の精度が低い原因は、債券市場における極性付与が複雑であるという点が挙げられる。そこで、本研究では特に債券市場を対象として、表現に対して景気要因における極性、債券における極性をそれぞれ付与することで、上記の問題を解決することを試みる。

1. はじめに

投資家は様々なデータを踏まえて投資判断を行うが、そのデータは膨大で多岐にわたるため、近年は膨大な金融情報を分析して投資判断を支援する技術が注目されている。その一例が「利上げ」のような金融に関連する語を収録した金融極性辞書である。

金融極性辞書について、これまでに株式に特化した「ネガティブ・ポジティブ」付与の研究が行われている[2][3][4]。しかし、その極性辞書を他の金融市場に当てはめると極性が異なる場合が多い。これは同じ表現であっても金融市場によって極性が異なる場合が存在するからである。例えば、「物価上昇」は株式市場においてはポ

ジティブと判断するが、債券市場においてはネガティブと判断する必要がある。また、既存の金融極性辞書には単語（あるいは複合語）が収録されており、例えば、「増加」という語について、一つの極性が付与されている。しかし、「消費が増加」や「コストが増加」のように、語の前後関係まで広く捉えてみると、必ずしもその語に付与されている極性が正しいとは限らないことがわかる。

我々はこれまで株式を対象として表現獲得、および、極性付与のための手法[1]を開発しており、良好な精度を得た。しかし、債券を対象として表現獲得、および、極性付与を行う場合、高い精度を達成できなかった。債券における表現への極性付与の精度が低い原因は、債券市場における極性付与が複雑であるという点が挙げられ

る。例えば、景気が好調である場合は、一般的には資金需要が増加し、それに伴って金利が上昇して債券相場は下落する。そのため、例えば「米経済が回復する」のような景気に関しての表現では、株式ではポジティブであるが債券市場においてはネガティブの極性を付与しなければならない。そこで、本研究では特に債券市場を対象として、表現に対して景気要因における極性、債券要因における極性をそれぞれ付与することで、上記の問題を解決することを試みる。

これまでに金融極性辞書についての研究は行われている[2][3][4]が、株式に特化した辞書が多く、辞書に収録されているのは単語(あるいは複合語)単位である。本研究では、債券市場に着目している点と、語の前後関係まで拡張した表現を自動的に獲得する点が異なる。

2. 提案手法の概要

本研究では、日経 QUICK 月次調査と日本経済新聞の記事を用いて、債券市場における表現にまで拡張した文字列での金融極性辞書の自動構築を行う手法を提案する。提案手法の概要を以下に示す。

Step 1: 日経 QUICK 月次調査と日本経済新聞の記事を用いて、債券市場における金融極性辞書に収録するのに適した語の候補(以降、「金融市場特徴語候補」と定義)を抽出する。

Step 2: 酒井らの手法[5]を用いて獲得した手がかり表現と Step 1 で抽出した金融市場特徴語候補をもとに、特徴的な語を表現にまで拡張した文字列(以降、「金融市場特徴表現」と定義)を獲得する。

Step 3: 獲得した金融市場特徴表現に極性の付与を行い、債券市場における金融極性辞書を構築する。

3. 金融市場特徴語候補の抽出

3.1 金融市場特徴語候補抽出の概要

Step 1: 日経 QUICK 月次調査に記載されている債券市場担当者からのコメント文(以降、「コメント文」と定義)を抽出し、コメント文と日本経済新聞記事をもとに Doc2vec のモデルを生成する。

Step 2: 生成した Doc2vec のモデルを用いて、債券市場

に関する記事を日本経済新聞記事から抽出し、コメント文と合わせた文章データ(以降、「拡張文章データ」と定義)を作成する。

Step 3: 酒井らの手法[5]を用いて、拡張文書データから共通頻出表現・手がかり表現を獲得する。

Step 4: 拡張文書データをもとに、Word2vec のモデルを生成する。

Step 5: 生成した Word2vec のモデルに獲得した共通頻出表現・手がかり表現を入力し、モデルから出力された語を金融市場特徴語候補として抽出する。

3.2 Doc2vec のモデル生成と類似記事抽出

日経 QUICK 月次調査に記載のコメント文を抽出する。しかし、抽出したコメント文だけでは金融市場特徴語を獲得するデータ量として不足しているため、それらのテキストデータをもとに Doc2vec を用いて、日本経済新聞記事より債券市場に関する記事を抽出する。Doc2vec のモデルを生成し、日経 QUICK 月次調査に記載のコメント文集合と日経新聞記事との類似度を求め、上位 50,000 記事に関連記事としてコメント文と合わせて拡張文書データとする。

3.3 共通頻出表現・手がかり表現獲得

酒井らの手法[5]を用いて、金融市場特徴語候補を抽出するための手がかりとなる表現を拡張文書データから自動的に獲得する。共通頻出表現・手がかり表現を獲得する手法について以下に述べる。なお、具体的な獲得手法については、文献[5]を参照されたい。

Step 1: 少数の手がかり表現(今回は「が好調」「が不振」を用いる)を人手で与え、それに係る節を取得する。

Step 2: 取得した節の集合から、その中で共通して頻繁に出現する表現(「売り上げ」など)を共通頻出表現として抽出する。

Step 3: 共通頻出表現に係る節を取得し、その中から新たな手がかり表現を抽出する。

Step 4: 獲得した手がかり表現から、それに係る節を取得する。

Step 5: Step 2 から Step 4 を新たな手がかり表現と共通

頻出表現が獲得されなくなる、もしくは、予め定めた回数まで繰り返す。

獲得した共通頻出表現・手がかり表現は形態素解析し、名詞と接頭詞、動詞の場合のみ結合した複合語とする。

3.4 Word2vec のモデル生成

債券市場における拡張文書データから金融市場特徴語候補を自動で取得するため、Word2vec のモデルを債券市場における拡張文書データを用いて作成する。Word2vec は単語の分散表現(ベクトル)を得る手法である。単語をベクトルで表現することで、単語間のコサイン類似度を計算することができ、意味のよく似た単語(類似度が高い単語)を抽出することができる。Word2vec のモデル生成時の学習データによって、同じ入力語であっても出力される類似度が高い単語が異なるため、債券市場における拡張文書データを学習データとすることで、債券市場における特徴的な語が出力されることを期待する。なお、学習データは形態素解析したのち、連続する品詞や接頭詞の場合は結合し、複合語として作成した。以下に、債券市場における金融市場特徴語候補の例を示す。

民間需要, 世界景気, インフレ懸念, 膨らむ,
ユーロ買い, 民間金融機関, 推し進める, 統計,
デフレ圧力, 引き下げられ, 跳ね上がる, 上昇基調,
景気対策, 積み上げる, 収益性, 価格変動リスク

4. 金融市場特徴表現の獲得

酒井らの手法[5]を用いて獲得した手がかり表現と抽出した金融市場特徴語候補をもとに、金融市場特徴表現を自動獲得する。表現獲得の概要を以下に示す。

Step 1: 獲得した共通頻出表現と手がかり表現の中から、手がかり表現のみを抽出する。

Step 2: 金融市場特徴語候補と抽出した手がかり表現を結合し、表現にまで拡張した文字列を生成する。

Step 3: 生成した文字列が表現として適しているか判定を行い、文字列を金融市場特徴表現として獲得する。

Step3 における生成した文字列が表現として適しているか

の判定は、生成した文字列が拡張文書データに含まれているかどうかで行い、含まれている場合のみ、その文字列を金融市場特徴表現として獲得する。以下に獲得した債券市場における金融市場特徴表現の例を示す。

債券価格が上昇し、値動きが続くと、歳出が多い、
国債金利が上がる、国内景気が回復、減少が加わる、
設備投資が増えると、国内需要が堅調、成長の続く、
債券売りが加速、債券相場が安定する、負債が減る、
利回り低下が加速した、利回り低下が目立った

5. 景気要因・債券要因への分類

「はじめに」において述べたように、債券市場を対象とした金融市場特徴表現の極性は、表現の対象が景気であるか債券であるかによって異なる。すなわち、同じ表現であっても、景気を対象としている場合と債券を対象としている場合では異なる極性を付与する必要がある。そのため、表現に対する極性付与を景気要因と債券要因で別々に行う。そこで、債券市場における拡張文書データを、景気要因に関する文と債券要因に関する文に分類し、それぞれの文集合を作成する。そして、2つの文集合のそれぞれの文に極性を付与し、極性付与された文を用いて、含まれている金融市場特徴表現に極性を付与する。

本章では景気要因に関する文と債券要因に関する文に分類する手法について述べる。なお、学習の精度を上げるため、拡張文書データのうち日本経済新聞の記事のみを利用した。

5.1 分類手法の概要

Step 1: 深層学習モデルにより、拡張文書データにおける文を景気要因または債券要因に関する文とそれ以外の文に分類する。

Step 2: 深層学習モデルにより、Step 1 で景気要因または債券要因に関する文として分類された文集合を景気要因に関する文と債券要因に関する文に分類する。

5.2 使用した深層学習モデルと学習の手順

概要の Step 1 および Step 2 で使用した深層学習モデル

は Bidirectional LSTM と 多層パーセプトロン(MLP)を組み合わせたモデルを用いた。学習モデルを図 1 に示す。

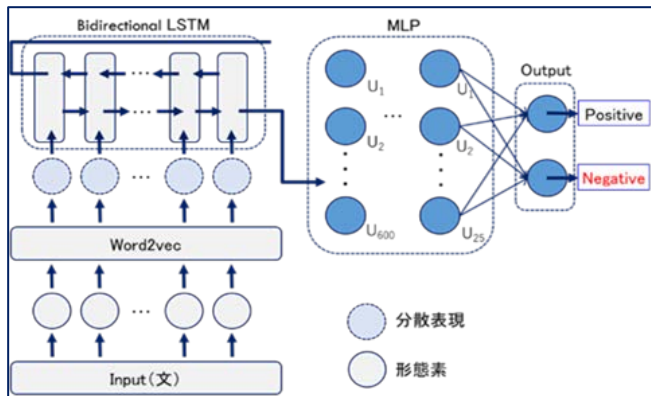


図 1 Bidirectional LSTM + 多層パーセプトロン(MLP)

学習は以下の手順で行う。

- Step 1: 学習データの文を形態素解析し、各語の分散表現(300次元)をLSTMに入力する。
- Step 2: 文頭から文末までのベクトルと文末から文頭までのベクトルを組み合わせ、多層パーセプトロン(MLP)の入力層(600ユニット)に入力する。
- Step 3: MLP の出力層は2ユニットとなっており、それぞれ、positive, negative の尤度を出力する。

MLP の中間層は9層(ユニット数300が3層, ユニット数100が3層, ユニット数25が3層)である。エポック数はStep 1では2エポック, Step 2では5エポックである。また、分散表現を得るために Word2vec を使用し、そのデータには日本経済新聞記事10年分を用いた。

5.3 学習データとテストデータの作成

概要の Step1, Step2 における深層学習のための学習データは、以下の手法にて自動生成した。学習データを自動生成することにより、人手で作成することは難しい量の学習データを用いて学習モデルを学習することができる。Step 1 における学習を行うために作成した学習データの詳細を以下に示す。

- ・正例データ(下記の条件を全て満たす文)
 - ー「景気」または「債券」を含む

ー手がかり表現を含む

- ・負例データ(下記の条件を全て満たす文)
 - ー「景気」とその分散表現の類似度が高い単語(「景気」を含めて20個)を含まない
 - ー「債券」とその分散表現の類似度が高い単語(「債券」を含めて20個)を含まない
 - ー手がかり表現を含まない
 - ー共通頻出表現を含まない

作成した正例と負例のデータを合わせたものを学習データ、債券市場における拡張文書データをテストデータとした。そして、テストデータにおいて、ポジティブの尤度が0.7より大きい文を景気要因または債券要因に関する文として抽出した。

概要の Step 2 における学習を行うために作成した学習データの詳細を以下に示す。

- ・正例データ
 - ーStep1 における学習データの正例において「景気」を含む文
- ・負例データ
 - ーStep1 における学習データの正例において「債券」を含む文

作成した正例と負例のデータを合わせたものを学習データ, Step 1 で抽出したデータをテストデータとした。テストデータにおいて、ポジティブの尤度が0.7以上の文を「景気要因に関する文」、ネガティブの尤度が0.7以上の文を「債券要因に関する文」として抽出した。

6. 金融市場特徴表現への極性付与

4章で述べた手法により獲得した金融市場特徴表現に対して、景気要因、債券要因、それぞれを対象とした極性の付与を行う。

6.1 金融市場特徴表現への極性付与の概要

- Step 1: 獲得した手がかり表現(「が好調」「が不振」など)を抽出し、その中から手がかり表現単体で考えたときに、極性が明らかなものに対して人手で極性(ポジ

ィブ, ネガティブ)の付与を行う。

Step 2: 5 章で抽出した景気要因に関する文の集合から、文中に4章で獲得した金融市場特徴表現が含まれている文のみ抽出する。(以降、「テストデータ」と定義)

Step 3: テストデータの中から Step1で極性を付与した手がかり表現が含まれている文に対してその極性を付与し、学習データを自動作成する

Step 4: 深層学習モデルを用いて、テストデータに極性(ポジティブ, ネガティブ)の付与を行う。

Step 5: テストデータに含まれる金融市場特徴表現に対して、その金融市場特徴表現が含まれているテストデータである文に付与された極性と尤度をもとに極性の付与を行う。

Step 6: Step 1 から Step 5 までを債券要因においても同様に行う。

6.2 手がかり表現への極性付与

3章において、酒井らの手法[5]を用いて、金融市場特徴語候補を抽出するための手がかりとなる表現を債券市場における拡張文書データから自動的に獲得を行った。

抽出した手がかり表現の中から手がかり表現単体で考えた時に、ネガティブまたはポジティブが明らかなものに対して極性を人手で付与する。なお、景気要因と債券要因では付与する極性が異なるため、それぞれに対応する極性付与を行う。例えば手がかり表現「が懸念されている」は、景気要因ではポジティブ、債券要因ではネガティブになる。

6.3 学習データとテストデータの作成

5 章で分類した景気要因に関する文または債券要因に関する文において、4 章で獲得した金融市場特徴表現が文中に含まれている文のみを抽出し、これらをテストデータとする。さらに、テストデータの中から人手で極性付与した手がかり表現が含まれている文にはその極性を付与する。なお、複数の手がかり表現が含まれる場合には最後に出現する手がかり表現の極性を文に付与し、極性が付与された文をまとめて学習データとする。これを景気要因と債券要因のそれぞれで作成する。

テストデータへの極性付与は 5 章で示した深層学習モ

デルで行っており、エポック数は景気要因と債券要因ともに 10 エポックである。以下に極性付与された文の例を示す。

- ・ 景気要因に関する文でネガティブとなった例
第二に、ここまでの景気回復の「余熱」効果が期待される
- ・ 債券要因に関する文でポジティブとなった例
市場では債券買いが進み、円高・ドル安に動いている

6.4 金融市場特徴表現への極性付与

極性付与されたテストデータ各文のネガティブ、ポジティブの尤度とその文に含まれる金融市場特徴表現をもとに、金融市場特徴表現に対して極性の付与を行う。具体的には、ある金融市場特徴表現を含む文の尤度の平均をもとめ、それを金融市場特徴表現の極性の尤度とする。さらに、ネガティブ、ポジティブの尤度のどちらかが 0.7 以上の表現のみを抽出する。

金融市場特徴表現の極性付与において、景気要因での例を表 1、債券要因での例を表 2 にそれぞれ示す。表 1 の極性は債券における景気要因の極性であり、景気が悪化すると債券市場における極性は positive が付与されることになる。

表 1 景気要因における金融市場特徴表現への極性付与

極性	金融市場特徴表現	negative 尤度	positive 尤度
positive	景気への悪影響を	0.013	0.987
positive	景気回復が遅れる	0.219	0.782
negative	状況が上向く	0.999	0.001
negative	相場が底堅かった	0.998	0.001

表 2 債券要因における金融市場特徴表現への極性付与

極性	金融市場特徴表現	negative 尤度	positive 尤度
positive	円買いが膨らんだ	0.159	0.842
positive	入札が堅調	0.091	0.909
negative	債券売りが進んだ	0.996	0.005
negative	国債保有が縮小	0.998	0.002

7. 評価

本手法についての評価は、景気要因における極性と債券要因における極性からそれぞれランダムに抽出した 50 個の金融市場特徴表現を対象として行った。なお、評価対象となる金融市場特徴表現の極性は、付与されている極性が正しいかどうかで判断した。評価結果を表 3 に示す。

表 3 評価結果

要因	精度(%)
景気	80
債券	58
全体	69

8. 考察

金融市場特徴表現における極性の精度は、景気要因においては 80%と高い精度を得ることができた。一方、債券要因においては 58%と景気要因に比べて高い精度を得ることができなかった。これは拡張文書データから債券要因に関する文を抽出する際に、景気要因に関する文も一部混在してしまっているからだと考えられる。

景気要因と債券要因の両方で出現する金融市場特徴表現において、それぞれの要因で極性が正しく付与できていれば、整合性があるといえる。表 4 にどちらの要因にも出現した金融市場特徴表現の極性ごとの例を示す。

表 4 景気要因と債券要因の両方で出現した
極性ごとの金融市場特徴表現

	景気要因 ポジティブ	景気要因 ネガティブ
債券要因 ポジティブ	・円買いが広がる ・ドル安が続くと	・投資が堅調な ・市場が堅調
債券要因 ネガティブ	・不安が強まり ・期待が後退	・収益が回復し ・業績が堅調な

表 4 から、どちらの要因でもポジティブとなっているものは、債券市場にとって良い表現になっていることが分かる。どちらの要因でもネガティブとなっているものは、景気にとって良い表現となっている。景気要因でポジティブ、債券

要因でネガティブとなっているものは、状況が悪い、もしくはこれから悪くなることを示唆する表現となっている。景気要因でネガティブ、債券要因でポジティブとなっているものは、状況が良い、もしくは良くなることを示唆する表現となっている。債券市場においては、景気にとってネガティブな表現はポジティブな表現として考え、債券にとってポジティブな表現はそのままポジティブな表現として考えることができるので、いずれも整合性が取れている。

9. まとめ

本研究では、金融テキストを用いて、債券市場における表現にまで拡張した文字列での金融極性辞書を自動構築するための手法を提案した。

具体的には、日経 QUICK 月次調査と日本経済新聞の記事を用いて、債券市場における金融市場特徴語候補を抽出し、手がかり表現と金融市場特徴語候補をもとに、金融市場特徴表現を獲得した。その後、獲得した金融市場特徴表現に極性の付与を行った。極性の付与は景気要因と債券要因で分けて行い、精度の向上を試みた。その結果、極性の精度は景気要因で 80%、債券要因で 58%、全体で 69%となり、比較的良好な結果を得ることができた。

今後の課題は、債券要因における極性の精度を向上させることである。

参考文献

- [1] 伊藤友助, 酒井浩之, 北島良三, 末廣徹, 稲垣真太郎, 木村柚里: 株式・債券・為替ごとの金融極性辞書の自動構築, 第 24 回金融情報学研究会, pp.211-218, 2020.
- [2] Tomoki Ito, Hiroki Sakaji, Kota Tsubouchi, Kiyoshi Izumi, Tatsuo Yamashita, Text-Visualizing Neural Network Model: Understanding Online Financial Textual Data, Advances in Knowledge Discovery and Data Mining. PAKDD 2018. Lecture Notes in Computer Science, Springer, vol 10939, pp 247-259, 2018.
- [3] 五島圭一, 高橋大志: 株式価格情報を用いた金融極性辞書の作成, 自然言語処理, Vol.24, No.5, pp.547-577, 2017.
- [4] 関和広, 柴本昌彦: 銘柄固有の金融極性辞書の構築, 第 18 回金融情報学研究会, 2017.
- [5] 酒井浩之, 西沢裕子, 松並祥吾, 坂地泰紀: 企業の決算短信 PDF からの業績要因の抽出, 人工知能学会論文誌, Vol.30, No.1, pp.172-182, 2015.

有価証券報告書からのリスク文抽出の試み

An attempt to extract sentences concerning contents of risks from securities reports

藤井 元雅¹ 坂地 泰紀² 佐々木 一³ 増山 繁¹

Motomasa Fujii¹ Hiroki Sakaji² Hajime Sasaki³ Shigeru Masuyama¹

¹東京理科大学経営学部

¹School of Management, Tokyo University of Science

²東京大学大学院工学系研究科

²Graduate School of Engineering, The University of Tokyo

³東京大学未来ビジョン研究センター

³Institute for Future Initiatives, The University of Tokyo

Abstract: Recognizing risks that are descriptive information is important to judge how companies manage their risks, that is, the consistency of the strategy when evaluating companies. So, in this research, risk is defined as "uncertainty of future results that can be obtained by taking actions", and we tried to extract the details of the risks recognized by each company from the text of the securities report. We also tried to classify the extracted risk based on their respective contents. The extraction method is investigating and classifying the expression patterns (possibly, etc.) used when expressing the content of risk, and using them as clues.

1. はじめに

今や環境・経済・社会が事業に与える影響は多くの企業にとって無視できないリスク要因であり、SDGs や ESG に寄与する活動に取り組まないこと自体もまたリスクになり得ると指摘されている[1]。また、Covid-19 の世界的流行に対する事業継続計画 (BCP) の策定内容が企業価値評価を行う投資家の間で重視され始めている。このような事業リスクをいかに把握・対処しているかを理解することは、企業活動や経営戦略の整合性の判断及び、企業価値評価の際に重要な役割を果たすと言える。例えば、上場企業が発行を義務づけられている有価証券報告書においては財務諸表だけでなく、業績要因やその企業の潜在的なリスク等多岐にわたる項目が記載されている。またその量は年々増加しており、この会計書類のみで様々な情報を入手することが可能になって

いる。現在、国や企業はこれらの情報公開に積極的になりつつある[2]。

一方で、実際の企業価値評価に際しては過年度や同業他社のもの等複数の有価証券報告書の確認が必要であることや前述のような記載内容の増加に伴い、処理しなければならない情報は膨大なものとなっている。すなわち、テキストマイニング等の人工知能分野の手法により情報を効率的に処理する必要性が高まっていると言える。

そこで本研究では、企業が想定するリスク内容を抽出・分類し企業価値評価に役立てる前段として、有価証券報告書内の「事業等のリスク」の項目において、企業毎に異なるリスク表現の方法を分析し、企業が想定するリスク内容を含む文を抽出する。対象として有価証券報告書を用いた理由としては、金融商品取引法で規定された開示資料であり、規格が同一であるためである。リスクの定義については、

リスクの内容が企業の行動の前提にあることに焦点を当てた定義が必要であると考え、今回の判断基準を採用した。投資家は社会的責任を含めた、その企業理念やスタンスが一貫しているかを重視しており、その判断材料には具体的な企業活動の情報が必要不可欠であること、またその活動がどのような不確実性を伴っているのか、ということも同様であると判断したためである。

先行研究として、キーワードを設定することによりどのようなリスクが記載されているかを確認する研究[2]は存在するが、あくまで全体像を把握するためのものであった。よって本研究においては、最終的な目的である多様化するリスクについての評価を行う際に具体的な内容についての把握が難しいと判断し、様々な手法を用いて抽出を試みた。

2. 関連研究

関連研究としては、キーワード検索を実行して、Scopus と Engineering Village のデータベースから関連記事を取得し、機械学習手法を利用して出版物の構造化されたレビューを提示し、エンジニアリングリスク評価を支援する研究[3]や、予期せぬ事態に対処し、リスク管理を可能にするための適切なサポートを提供するために、機械学習、特に深層ニューラルネットワーク(DNN)モデルに基づくリスクアセスメントアプローチの提案を行っている研究[5]が挙げられる。財務諸表を用いたものとしては、テキストマイニング手法を用い財務諸表に報告されたテキストリスク開示からエネルギー企業のリスク要因を総合的に特定し、またそこからリスク要因階層システムの構築が試みられている[6]。

また、企業が想定するリスクの内容については、リスクアプローチの洞察と予期せぬ事象に対する実用的なガイドラインを提示している文献[7]や、リスク評価が実際にリスクに及ぼす影響について分析している文献[8]がある。

3. リスクの定義

リスクの定義について、リスクマネジメントの国際規格「ISO31000:2018 リスクマネジメントー指針」[9]において、「effect of uncertainty on objectives(目的に対する不確実性の影響)」とされている。

一方、有価証券報告書の記載内容を定めている「企業内容等の開示に関する内閣府令」の2019年の改正[10]においては、記載すべきリスクは「連結会社の経営成績等の状況の異常な変動、特定の取引先・製品・技術等への依存、特有の法的規制・取引慣行・経営方針、重要な訴訟事件等の発生、役員・大株主・

関係会社等に関する重要事項等、投資者の判断に重要な影響を及ぼす可能性のある事項」とされている。すなわち有価証券報告書においては、企業の目的ではなく、それを実現するための行動(事業活動)によって生じる不確実性により、焦点が当てられていると言える。

例えば、2018年12月期のヤマハ発動機株式会社(以下、ヤマハ発動機)においては「当社グループの日本における主力製造拠点は、予想される南海トラフ巨大地震の震源域近傍に集中している」といった文言が確認できる。これは、ヤマハ発動機は目的を達成するために生産活動を行っていることは明白であるが、製造拠点の確保という現在の企業活動こそが直面しているリスクを表していると言える。

以上の点や文献[11]を参考とし、本研究では、リスクを「行動したことにより獲得できる将来の結果の不確実性のこと」と定義する。なお、ここでの結果とは企業の業績のことであり、不確実性とは、どのような状態や結果が出現するかはわかっているが、状態や結果の出現確率がわからない状況、すなわち、意思決定環境に応じた不確実性の分類における「不確実性下の曖昧性下」にあたる状況[12]としている。これは、前述の巨大地震の例を始めとした企業が直面する(有価証券報告書に記載される)多くの事象の出現確率の測定が困難であるためである。言い換えると、企業は現在の企業活動を踏まえた上で業績を予測しているが、それらは当然実際とは異なる場合があり、それらの要因となるものをリスクと定義しているということである。

4. リスク文へのタグ付け

評価データには、日経225に指定されている企業からランダムに70社を選択し、その有価証券報告書を用いた。有価証券報告書はPDFファイルをテキスト化し、「事業等のリスク」の項目を抽出し、文単位に分割した。該当する文は計5,007文であり人手でタグを付与した結果、リスクの内容を含む文(リスク文と定義する)は2,588文、リスク文でない文は2,419文であった。このうち7割にあたる3,507文を学習データとして用いた。

5. 分類手法

本節では、本研究で用いる分類手法について紹介する。以下に本研究で用いた分類手法を示す。

パターンマッチング

複数の文字列や図形等を比較し同一あるいは類似したものであるかどうか、またどこに出現するのか

を調査する．詳細については 5.1 節で後述する．

SVM¹

機械学習の一種であり，データ空間上に識別超平面を構築し，その際には分類がきわどいデータのみを上手く選んで，それらと識別超平面がなるべく離れるように学習を行う方法である．

Logistic Regression

定性的データの従属変数を予測・説明するために用いられる多変量解析手法であり，目的変数に対する影響の大きさを調べることができる．

Random Forest

Random 重複を許すランダムサンプリングによって多数の決定木を作成し，各木の予測結果の多数決をとることで最終予測値を決定する．

Bidirectional LSTM

系列データをうまく扱うために開発された Recurrent Neural Network(RNN)の一種である Long Short-Term Memory(LSTM)[13]を用いる．本研究では，文頭から文末までと，文末から文頭までの双方向の情報を利用したいことから，Bidirectional LSTM(BiLSTM)を採用した．これは，語の曖昧さ解消など前方の文脈だけでなく後方の文脈が必要な場合があり，双方向の方が性能は高い場合が多いためである．特に，有価証券報告書は一文が長い傾向にあるため，前・後方の文脈の両方を考慮する必要がある．片方向だけでは情報が落ちてしまう可能性がある．加えて，要素間の関係性や全体のコンテキストを考慮する Attention 機構を適用している．

BERT

BERT は，Devlin ら[14]によって提案された大規模言語モデルで，様々なタスクにおいて優秀な成績を収めている

本研究では，fine-tuning することで，リスク文の抽出に利用する．

5.1. パターンマッチングによる抽出

本研究においては，有価証券報告書においてリスクを表現するパターンとして以下の 2 つに分類した．なお，以下の分類においては文献[15]を参考とした．

まず，論理文(複文の従属節の部分の前件，主節の部分を後件とするとき，前件の命題の真偽が後件の真偽に関連している関係(因果関係)を表す複文)に用いられる接続詞のうち，前件がまだ発生していない(前件が既に発生している場合，それは不確実なものではなくリスクの定義から外れる)場合に用いられるもの，あるいはこれに置き換えることができる表現．

次に，出来事の内容(命題)を可能性があるものとしている，あるいはこれに置き換えることができる表現．なお，このような条件を満たす場合でも，命題が「業績が低下する」「財政状態が悪化する」といった企業活動の最終的な成果を表している場合は除外される．理由としては，前述のような命題はリスクの定義における「結果」に該当するものであり，抽出すべき内容と異なっている(抽出すべきは結果が不確実な理由)ためである．

最後に，上記の表現には当てはまらないが，「～変動の影響を受ける」といった間接的な表現や「市場価格」といった不確実性が想起される語による表現．

上記 3 つの表現をそれぞれ，仮定表現，可能性表現とする．それぞれの表現のパターンの具体例は以下の通りである．

i. 仮定表現を示すパターンの例

場合(には は においては) ときは すれば すると 局面では	計 7 例
------------------------------------	-------

ii. 可能性表現を示すパターンの例

可能性(がある 生じる 否定できない 皆無ではない ないとは言えない) リスク(がある が考えられる が存在する が内在する を有している を含む にさらされている となり得る が高まっている を抱えている を負っている は避け られない を伴う) ことがある 想定される かもしれない 考えられる 場合がある 恐れがある 懸念がある	計 25 例
--	--------

6. 評価実験

どの分類手法が本タスクにおいて有効かを調べるために，評価実験を行った．本研究における後述の手法いずれにおいても学習の際には，Mecab²による形態素解析を用いて，形態素を抽出し，素性に利用している．また，係り受け解析器としては Cabocha[16]を用いた．Logistic Regression, Random Forest の実装には gensim を利用し，SVM の実装としては学習器には SVM-light を用いた．BiLSTM の実装には，Pytorch を利用し，BERT は東北大学乾研究室が公開している日本語 Wikipedia から学習したモデルを利用した．

なお，精度，再現率，F 値の算出にはいずれもマクロ平均を用いている．また，評価実験に用いたデータの詳細は表 1 に示す．

¹ <http://svmlight.joachims.org/>

² <http://taku910.github.io/mecab/>

	正例	負例	総数
学習データ	1,834	1,671	3,505
検証データ	498	503	1,001
テストデータ	256	245	501

表1 データ内容

	精度	再現率	F値	抽出数
可能性表現	0.44	0.95	0.6	2,470
仮定表現	0.75	1.00	0.85	1,590

表2 パターンマッチングの評価結果

	精度	再現率	F値
パターンマッチング	—	—	—
SVM	0.93	0.80	0.87
Logistic Regression	0.90	0.90	0.90
Random Forest	0.91	0.91	0.91
BiLSTM	1.00	1.00	1.00
BERT	0.99	0.99	0.99

表3 評価結果

7. 考察

実験結果を表2・3に示す。本手法においてはパターンマッチングに比べ、SVMやLR、RFが再現率を除き、高い性能を示した。これによりリスクを表現する語形がそうでない文においても多く用いられていると考えることができる。以下は、抽出が適切に行われなかった文の一例である。

①当社グループの財政状態及び経営成績に影響を及ぼす可能性のあるリスクには以下のようなものがあります。

(富士フイルムホールディングス株式会社)

②しかしながら、精密な故に荷役や輸送段階における軽微な衝撃等によって全損害となり、高価格化が故に損害が拡大するリスクをはらんでおります。

(キヤノン株式会社)

③当社グループの業績は上半期と下半期を比較した場合、下半期の業績がよくなる傾向にあります。

(横浜ゴム株式会社)

④このような急激な価格変動が長引かない、あるいは、これまでこのような変動がなかった市場で発生しないという保証はありません。

(スズキ株式会社)

①は「可能性表現」を含むとして抽出されたが、これは記載するリスクについて説明する文章であり、リスクの内容を抽出できたとは言えない。逆に、②は「リスクがある」という言い方を変化させたものであり、これに限らず企業によって多くの異なる表現が確認できる。③は仮定表現として抽出されたものの、この「場合」は条件を説明するために用いられており、不確実な事象を示しているものではない。また、④のように「可能性表現」や「仮定表現」の

いずれにも該当しないが「価格変動」といった語(変動自体が予測することができないというニュアンスを含んでいる)や「保証はない」という遠回しな言い方でリスクを表現している文はリスク文として抽出することができなかった。特に④のような事例を抽出するにあたっては、語形によるリスク内容の抽出には限界があると考えられる。

さらに、いずれの手法よりもBiLSTMやBERTの学習による性能が極めて高いことから、リスクの内容を含む文が定型的であり多様性があまりないこと、リスクを表現するのに際し文脈あるいは語句の順番が強い影響を与えていると考えることができる。なお、文が定型的であるということについては、分析対象が有価証券報告書という法令により形式が定められた書類であることも一因であると考えられる。

また、誤差だと考えられるが、BERTよりもBiLSTMの結果が上回った。このことから、対象言語データを有価証券報告書に絞る限りは、BERTほどの複雑なモデルを用いる必要性が低いと考えられる。すなわち、文脈情報を利用できていれば、十分に分類可能なタスクであるということがわかった。

8. まとめ

本研究では、有価証券報告書からリスクの内容を含む文抽出を様々な手法を用いて行った。その中においてはBiLSTMにおける学習が、精度・再現率・F値のいずれも非常に高い性能を示した。しかし、文単位で抽出するとリスクと関係のない内容が混入する恐れがある。そのため今後、文単位ではなく表現単位での抽出を行う予定である。また、抽出したリスクの内容について分類を行う等、抽出された文の事業リスク把握に対する有効性について検証していきたい。

参考文献

- [1] 経済産業省,「SDGs 経営ガイド」, 2019 年 5 月.
- [2] 一般財団法人企業活力研究所,「新時代の非財務情報開示のあり方に関する調査研究報告書～多様なステークホルダーとのより良い関係構築に向けて～」, 2018 年 3 月.
- [3] 張替一彰,「有価証券報告書事業リスク情報を活用したリスク IR の定量評価」,『証券アナリストジャーナル』, 第 46 巻第 4 号, pp. 32-44, 2008 年 4 月.
- [4] Jeevith Hegde, Børge Rokseth, "Applications of machine learning methods for engineering risk assessment – A review", *Safety Science*, Volume 122, 2020.
- [5] Lu Weiab, Guowen Liab, Xiaoqian Zhua, Xiaolei Suna, Jianping Liab, "Developing a hierarchical system for energy corporate risk factors based on textual risk disclosures", *Energy Economics*, Volume 80, 2019.
- [6] Nicola Paltrinieria, Louise Comfortb, Genserik Renierscde, "Learning about risk: Machine learning for risk assessment", *Safety Science*, Volume 118, 475-486, 2019.
- [7] Terje Avena, Bodil S.Krohn, "A new perspective on how to understand, assess and manage risk and the unforeseen", *Reliability Engineering & System Safety*, Volume 121, 1-10, 2014.
- [8] Graham D.Creedy, "Quantitative risk assessment: How realistic are those frequency assumptions?", *Journal of Loss Prevention in the Process Industries*, Volume 24, Issue 3, 203-207, 2011.
- [9] International Organization for Standardization, "ISO 31000:2018 Risk management — Guidelines", 2018.
- [10] 金融庁,「企業内容等の開示に関する内閣府令の一部を改正する内閣府令」, 2019 年.
- [11] 伊藤邦雄,『新・企業価値評価』, 日本経済新聞出版社, 2014 年 4 月
- [12] 竹村和久, 吉川肇子, 藤井聡,「不確実性とリスク評価ー理論枠組みの提案ー」,『社会技術研究論文集』, Vol.2, pp.12-20, 2004 年 10 月.
- [13] Sepp Hochreiter and Jürgen Schmidhuber, Long short-term memory, *Neural computation*, Vol. 9, No. 8, 1735–1780, 1997.
- [14] J. Devlin, M. Chang, K. Lee, and K. Toutanova, "BERT: pretraining of deep bidirectional transformers for language understanding", *CoRR*, 2018.
- [15] 庵功雄,『新しい日本語学入門』, スリーエーネットワーク, 2012 年 4 月
- [16] 工藤拓, 松本裕治,「チャンキングの段階適用による日本語係り受け解析」,『情報処理学会論文誌』, vol.43, no.6, pp.1834-1842, 2002.

経済データを用いた政府の景気基調判断文の生成 とバイアスの検証

Development of a model for generating the government's "Assessment of the current state of the economy" based on economic indicators and analysis of its tendencies

末廣徹^{1,2} 木村柚里¹ 稲垣真太郎¹

Toru Suehiro^{1,2}, Yuri Kimura¹, and Shintaro Inagaki¹

¹ みずほ証券金融市場調査部

¹ Fixed Income Research Department, Mizuho Securities, Co., Ltd.

² 法政大学大学院経済学研究科経済学専攻

² Graduate School of Economics, Hosei University

Abstract: In this paper, we examine whether it is possible to generate the government's "Assessment of the current state of the economy" by the Japanese government using several economic indicators that are believed to be consistent with the Japanese economic trend. In the Monthly Economic Report released by the Cabinet Office, the government publishes the government's "Assessment of the current state of the economy" along with expressions such as "recovering," "worsening," and "standstill", etc. In this paper, we developed a model to generate the government's "Assessment of the current state of the economy" and tested the accuracy of the predictions. In addition, we examined which economic indicators are likely to influence the government's "Assessment of the current state of the economy". It is expected that this analysis will be useful in predicting the government's policy decisions.

1. はじめに

政府や日銀は景気や物価の状況を文章で示す「基調判断」を公表している。日銀は四半期に1度の「展望レポート」で、政府は内閣府から発表される「月例経済報告」でそれぞれ示している。いずれも、政府や日銀による経済環境の評価を知る上で、金融市場において注目されることが多い。例えば、政府による景気判断が悪化すれば、経済をテコ入れするための経済対策が行われる可能性が高いという予想が増えるだろう。もっとも、政府や日銀の「基調判断」がどのような分析に基づいて決定しているのかは釈然としない面もある。そこで、本稿では様々な経済データをインプットとして、政府が「月例経済報告」で示している「基調判断文」をアウトプットするAIモデルを作成し、政府の「基調判断文」がどのように決定されているのかという実験を行った。研究分

野としては構造化データの活用をテーマとした研究分野の1つであるデータを自然言語に変換し、理解可能性を拡張する“Data-to-Text”である。

金融経済の数値データから文章を生成するという試み自体は過去にも分析された例があるものの（[1]など）、過去の研究は市場参加者に対する情報提供や業務効率化という側面が強い。一方、本稿が分析対象とする日本政府の基調判断文の「クセ」を学習することで、事前に政府の景気認識の変化やそれに伴う政策変更の予想に役立てることができるなど、フォワードルッキングな利用も大きなモチベーションとなっている。

2. 関連研究

政府や日銀のテキストデータを用いた分析は複数行われてきたが、多くの研究がテキストデータをセンチメントなどの数値データに変換することで、景気や市場の動向を予測することがテーマとなってきた。[2]は「月例経済報告」の言葉に注目し、その変化から景気指標を作成した。[3]は日銀の「金融経済月報」から金融市場の動向を分析した。[4]は、景気

連絡先: みずほ証券株式会社金融市場調査部
〒100-0004 東京都千代田区大手町 1-5-1 大手町ファーストスクエア
E-mail: toru.suehiro@mizuho-sc.com

ウォッチャー調査をもとに、月例経済報告や展望レポートをベースとした指数を作成した。これらの先行研究のように、基準を付けたり比較したりすることが困難であるテキストデータを辞書や深層学習を用いて数値データに変換することは、テキストマイニングの分野では王道であり、多くの研究が蓄積している。

他方、本稿が注目している“Data-to-Text”の応用については、応用例は少ない。[1]は市場データ（日経平均）を用いて概況テキストを自動生成する研究であり、研究のプロセスは本稿と同様である。ただし、[1]は人間が行っていたタスクの自動化を目的としている一方、本稿は“Data-to-Text”のモデルを作成することで、人間が行っている文書作成の「クセ」を読み解くことが目的である。このような研究の蓄積はこれまで見られていない。

3. 使用データ

内閣府月例経済報告の1998年1月から2019年8月で示される景気の基調判断のテキストデータを用いた。月例経済報告は景気に対する日本政府の公式見解を示す資料であり、「月例経済報告等に関する関係閣僚会議」において経済財政政策担当大臣を中心に議論されて内容が決まる。表1に「景気の基調判断」の例を示す。「景気の基調判断」では景気動向指数も参考にされるものの、CI一致指数などによって機械的に基調判断が決定するわけではない。従って、日本政府の基調判断はどのような基準で作成されているのか不透明な点が多いことで知られている。

基調判断の文章の構成についても決まりがあるわけではなく、「景気は、回復している」などシンプルな構成の場合もあれば、「景気は、輸出や生産に弱さがみられるが、持ち直している」など様々な付帯条件が記されることもある。とはいえ、ほとんどのケースにおいて基調判断は「景気は」という語で始まる文章であり、文の最後は「弱含んでいる」「改善に足踏みがみられる」「持ち直しの動きがみられる」などのように結論が示されていることが特徴となっており、一定の精度で文章の生成が可能であると期待できる。なお、分析に用いたデータセットでは、「東日本大震災の影響により」や「復興需要等を背景として」といった経済データだけでは判断しにくいとみられる文言はセンテンスから取り除いた。他にも、輸出や個人消費、生産と言った細かい表現については景気全体の水準や方向性とは直接的な関係がないことから、これもデータから除いた。さらに、2センテンス以上から構成されているコメントについては、初めのセンテンスのみを取り出してターゲットデータとした。

表1 月例経済報告の基調判断の例文

景気は、おおむね横ばいとなっているが、イラク情勢等から不透明感が増している。
景気は、おおむね横ばいとなっている。株価やアメリカ経済の動向など、我が国の景気を巡る環境に変化の兆しがみられる。
景気は、依然として厳しい状況にあるものの、復興需要等を背景として、緩やかに回復しつつある。

テキストデータについては、助詞、助動詞、非自立的動詞、接続詞は区切らず、手前で出現したトークンに接続した（例えば下記）。

[“景気は”, “,”, “緩やかに”, “回復しつつ”, “ある”]

作成したトークンをリストに格納し、ID化することで埋め込み処理を可能にした。

一方、文章生成の元となる経済データは、景気動向指数のCI一致指数の個別系列(9系列)を中心に、CI先行系列(11系列)、CI遅行系列(9系列)を用いた。CI(Composite Index)は生産、消費、雇用など経済活動での重要かつ景気に敏感に反応する様々な指標を統合して1つの指標にすることによって、景気の現状把握を行うために作成されている。

景気動向指数には、景気に対して先行して動く先行指数、ほぼ一致して動く一致指数、遅れて動く遅行指数の3つの指数がある。そのうち一致指数のデータを中心に内閣府の景気動向指数研究会での議論を踏まえ、景気循環の転換点である景気基準日付(景気の山・谷)を設定している。政府の景気に対する基調判断と、景気動向指数研究会の判断は必ずしも一致しないものの、一般的に景気の基調判断を決めるデータセットとしては過不足がないものと言える。

指標データに関して、本稿では当月を除く過去12ヶ月分を入力データとした。当月分については、月例経済報告が公表された段階で経済指標が発表されていないものが多いことから、基調判断を決める際の参考にはできないからである。データセットの合計は260で、ここから80%を訓練データ、20%を検証用データとして学習を行ったすなわちモデル入力データのサイズは208である。

なお、指標データを用いる際には、月次の差分を標準化してから用いた。

4. モデル

本稿では文書生成タスクについて encoder-decoder モデルを使用した。Encoder, Decoder 内部のアーキテクチャにはどちらも GRU を使用した。GRU とはゲート機構を持つ回帰型ニューラルネットワークであり、LSTM と同等の精度が期待されるが、出力ゲートが特に小規模なデータセットに対しては GRU が有効とされている。

モデル構築における条件について、パラメータの最適化手法には Adam を使用し、ミニバッチのサイズを 12, encoder の隠れ状態の次元を 256, epoch 数を 100 とした。形態素解析器には Mecab, モデルの実装には Pytorch を使用した。

モデルの評価には BLEU-4 スコアを用いた。データサイズが限られているため評価データを用いない評価を試みた。具体的には validation data に対する BLEU-4 スコアの最大値を取得するという試行をそれぞれ 10 回行い、その平均値を求めた。結果は 60.3 となり、良好とされる目安である 40 を上回った²。


5. 分析

5-1. 経済データの範囲

モデルの作成条件と BLEU-4 のスコアを比較することで、月例経済報告の基調判断の特徴を分析した。まずは、学習データである経済指標 (CI 一致指数の個別 9 系列) の過去データは何ヵ月分用いるのが最も再現性が高いかを調べた。最も基調判断分の再現性の高いデータ入力する数を調べることで、政府が過去何ヵ月分のデータセットを見て基調判断文を考えているのかを予想することができる。

訓練データを 2~20 ヶ月分まで変化させて BLEU-4 スコアを比較すると (図 1), 2~12 ヶ月までは過去データの数を増やした分だけ BLEU-4 スコアが上昇する一方、それ以降はデータ数を増やしてもスコアの改善が限定的である。つまり、過去 12 ヶ月より前のデータを追加しても基調判断の生成にはほとんど影響を与えていないことが分かった。政府が基調判断文を作成する際には、過去 12 ヶ月程度のデータが参照されている可能性が高いと言えよう。


図 1 訓練データの過去データ数と BLEU-4 スコア



5-2. 基調判断に影響を与える指標

モデル作成に用いた経済指標 (CI 一致指数の個別 9 系列) のうち、1 つだけを訓練データとして BLEU-4 スコアを比較すると、図表 2 のようになった。CI 一致指標の 9 系列は「C1: 生産指数 (鉱工業)」「C2: 鉱工業用生産財出荷指数」「C3: 耐久消費財出荷指数」「C4: 所定外労働時間指数 (調査産業計)」「C5: 投資財出荷指数 (除く輸送機械)」「C6: 商業販売額 (小売業) (前年同月比)」「C7: 商業販売額 (卸売業) (前年同月比)」「C8: 営業利益 (全産業)」「C9: 有効求人倍率 (除く学卒)」だが、C7 (商業販売額) の BLEU-4 スコアが低く (再現性が低い), C8 (営業利益) が高い (再現性が高い) ことが分かった。他方、その他の指標間ではそれほどスコアの差がなかった。この結果から、政府が基調判断文を作成する際には、CI 一致指数の 9 系列の中では「営業利益」が重視されている可能性が高いと言えよう。

図 2 経済指標別の BLEU-4 スコア




さらに、学習データの範囲を CI 一致指数以外にも広げた結果を検証した (図 3)。CI 先行指数を用いた場合の BLEU-4 スコアは CI 一致指数と同様に良好な結果 (再現性が高い) となることが分かった。一方、CI 遅行指数のスコアは他に比べやや低い (基調判断に対する影響は限定的) ことが分かった。

また、個別系列をそれぞれ別のデータとして学習した場合は、CI 一致系列の 9 系列を用いた場合の BLEU-4 スコアが最も高かった。僅差ながらも全 29 系列すべてを用いた場合よりも高くなったことから、基調判断を予想する場合は CI 一致指数の個別系列の変化を確認することが特に重要と言える。

² 本稿におけるモデルの詳細は[5].

図3 景気動向指数（CI 先行指数，CI 一致指数，CI 遅行指数）別の BLEU-4 スコア



5-3. 訓練データの期間による比較

最後に、政府による基調判断文の作成において、構造変化があったかどうかの検証を行った。政府の基調判断文は常に同じ判断基準で公平に行われていることが望ましいことは間違いないが、基調判断文作成のルールが明文化されているわけでもなく、そのときの政権によって基調判断文の傾向が変わる可能性もあるだろう。そこで、直近で政権交代が生じた（民主党政権から自民党の安倍政権に変わった）タイミングの前後で「基調判断の判断基準が変わったかどうか」を検証した。

具体的には、12 年末までのデータセットを学習データとしたモデルを作成した上で、13 年 1 月以降のデータセット（過去 12 ヶ月分の CI 一致指数の個別 9 系列）から想定される基調判断の生成を行った。安倍政権のアベノミクス以降のデータを学習データから外すことにより、アベノミクス前の判断基準を反映したモデルを作成することができる。仮に判断基準が変わっていないのであれば、実際の基調判断を再現することが可能であるはずである。逆に、再現ができなければ政府の基調判断の判断基準に変化があった可能性が疑われる。

19 年以降の基調判断について、実際の基調判断とアベノミクス前のモデルを使って生成した文を比較すると（表 2）、明らかにモデルの生成文の方が弱気

な表現が並んだ。つまり、アベノミクス以降（13 年 1 月以降）は基調判断の判断基準が変化し、より強気（楽観的）になっている可能性が高いと言える。

19 年 12 月の基調判断については、実際は「弱さが一段と増しているものの」という警戒文がついてはいるが、「緩やかに回復している」という表現は前月から維持された。しかし、アベノミクス前のモデルを使った生成文は「一層厳しさを増している」という非常に弱い表現となった。

また、実際の基調判断を用いたスコア（スコアの作成方法は 5 段階評価）と、アベノミクス前のモデルが生成した文のスコアを比較すると（図 4）、後者の方が CI 一致指数と連動していることが分かった。つまり、アベノミクス前までは CI 一致指数に連動した基調判断が発表されていたとみられる一方、アベノミクス以降は基調判断の判断基準が強硬化したことで連動性がなくなってしまったと言える。

少なくとも、アベノミクス前後において、基調判断文の作成のルールが政府内で変化した可能性が高い。以上から、モデルの作成期間を変更することにより、構造変化が生じている可能性を示すことができた。

図4 実際の基調判断スコアと、アベノミクス前のモデルが生成した基調判断スコア




表 2 19 年以降の基調判断と、アベノミクス以前の訓練データを用いたモデル推計値

	実際の基調判断の文	アベノミクス前のモデルを使った生成文
19年1月	景気は、緩やかに回復している	景気は、依然として厳しい状況にある
19年2月	景気は、緩やかに回復している	景気は、このところ停滞している
19年3月	景気は、このところ輸出や生産の一部に弱さもみられるが、緩やかに回復している	景気は、一部に弱い動きが続いており、回復が緩やかになっている
19年4月	景気は、このところ輸出や生産の一部に弱さもみられるが、緩やかに回復している	景気は、一部に弱い動きが続くものの、緩やかに回復している
19年5月	景気は、輸出や生産の弱さが続いているものの、緩やかに回復している	景気は、一部に弱い動きがみられ、このところ回復が緩やかになっている
19年6月	景気は、輸出や生産の弱さが続いているものの、緩やかに回復している	景気は、依然として厳しい状況にあるが、一部に持ち直しの動きがみられる
19年7月	景気は、輸出を中心に弱さが続いているものの、緩やかに回復している	景気は、このところ弱い動きとなっている
19年8月	景気は、輸出を中心に弱さが続いているものの、緩やかに回復している	景気は、このところ弱い動きとなっている
19年9月	景気は、輸出を中心に弱さが続いているものの、緩やかに回復している	景気は、このところ弱い動きとなっている
19年10月	景気は、輸出を中心に弱さが長引いているものの、緩やかに回復している	景気は、依然として厳しい状況にあるものの、このところ上向きの動きがみられる
19年11月	景気は、輸出を中心に弱さが長引いているものの、緩やかに回復している	景気は、引き続き低迷状態が長引き、はなはだ厳しい状況にある
19年12月	景気は、輸出が引き続き弱含むなかで、製造業を中心に弱さが一段と増しているものの、緩やかに回復している	景気は、引き続き停滞し、一層厳しさを増している

6. 結論

本稿では、日本の経済指標によって日本政府の基調判断文のテキストデータを生成することができるのか、という検証を行った。数値データである経済指標から基調判断文のテキストデータを作成するという“Data-to-Text”のタスクにおいて、深層学習を使うことにより、一定の精度で文章生成が可能であることが分かった。

また、作成したモデルを用いて政府の基調判断文作成の特徴やバイアス（いわゆる「クセ」）を検証した。具体的には、(1)入力する経済指標のデータの時系列方向でのデータ数を変更することにより、政府は概ね過去 12 ヶ月程度のデータを参考に基調判断文を作成している可能性が高いことを示し、(2)入力する経済指標の種類を変化させることにより、政府は「営業利益」の項目を重視している可能性が高いことを示した。さらに民主党政権から自民党の安倍政権に政権交代したタイミングの前後（アベノミクス前後）でモデルを分割したところ、アベノミクス以降の基調判断文はそれ以前と比較して景気に対して強気な基調判断文を選択していたことを示した。

本稿が分析対象とした政府の基調判断文に限らず、データを文章で説明するケースは少なくない（各国中央銀行の声明文など）。深層学習を用いたモデルを作ることで、各種基調判断文を予測することは市場参加者にとって有益だろう。また、本稿のようにモデルを検証することによって基調判断文の妥当性を議論することも可能である。数値データと異なり、文章の正しさに疑義がある場合は、解釈の仕方などによって水掛け論になってしまうことが多いが、モデルを作成することによってその一貫性を問うことも可能になる。本稿の研究がこのような応用例の一例となるだろう。

参考文献

- [1] 村上聡一郎, 渡邊亮彦, 宮澤彬, 五島圭一, 柳瀬利彦, 高村大也, 宮尾祐介: 時系列数値データからの概況テキストの自動生成, 言語処理学会 第 23 回年次大会 発表論文集, 2017
- [2] 山澤成康: 景気指標としての月例経済報告, JCER Discussion Paper 124, 日本経済研究センター, 2009
- [3] 和泉潔, 後藤卓, 松井藤五郎: 経済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 Vol.52 No.12, 3309-3315 頁, 2011
- [4] 山本裕樹, 松尾豊: 景気ウォッチャー調査の深層学習を用いた金融レポートの指数化, 第 30 回人工知能学会全国大会, 2016

- [5] 木村柚里, 末廣徹, 稲垣真太郎: 小規模データセットを用いた景気の基調判断文自動生成, 言語処理学会 第 26 回年次大会, 2020

解釈性を持つマクロファクター構成手法

Macro Factor Extraction Method with Interpretability

野間 修平^{1*} 中川 慧¹ 伊藤 彰朗¹
Shuhei Noma¹ Kei Nakagawa¹ Akio Ito¹

¹ 野村アセットマネジメント株式会社

¹ Nomura Asset Management Co., Ltd.

Abstract: 資産配分の文脈において、各資産の価格変動を横断的に説明する共通因子を構成し、これを介して資産配分を決定するアプローチが注目されている。このような価格変動の共通因子はリスクファクターと呼ばれる。特に、マルチアセット市場 (multi-asset market) を説明するリスクファクターはマクロ経済的な概念と紐づけて解釈されることが多く、マクロファクターとも呼ばれる。リスクファクターの構成手法としては主成分分析が広く用いられている。しかし、主成分分析によって構成されるリスクファクターは上位のものを除き、その解釈が困難であるという問題点がある。リスクファクターを介して資産配分を決定するアプローチにおいては、より多くのリスクファクターを解釈することが望ましく、このような主成分分析の性質は実務上重大な問題である。本研究では上に掲げた主成分分析の問題点を解決する次元削減手法を提案し、人工データ及びマルチアセット市場データを用いた実験によってその有効性を示す。マルチアセット市場データを用いた実験では、提案手法によって構成されたマクロファクターを貿易、金融政策、外交政策など、相異なるマクロ経済的な概念と紐づけて解釈する。

1 序論

Markowitz によって提案された平均分散アプローチ [9] にかわり、推定が難しい期待リターンを使用せず、推定リスクの情報のみを用いてポートフォリオを構築する手法であるリスクベース・アプローチが近年盛んに研究されている [12] [5] [8] [4]。中でもリスクパリティ戦略はその有用性が実証的に示されており、実務家を中心に注目を集めている [12] [8]。一方、リスクパリティ戦略に対する批判も存在する。すなわち、リスクパリティ戦略は各資産のリスク寄与度を分散させているにすぎず、各資産のリスクを横断的に説明するリスクの源泉に関して十分な分散がなされていないという批判である [10] [3]。このようなリスクパリティ戦略の問題点に対する処方箋として、Meucci は diversification index と呼ばれるリスクの源泉に関する分散の程度を評価する指標を導入し、これを最大化する戦略を提案している [10]。また、Roncali and Weisang は各資産の価格変動を横断的に説明する共通因子であるリスクファクターの概念を導入し、これを制御対象とすることでリスクの源泉を分散させる Factor Risk Budgeting 戦略

を提案している [13]。

続いて、資産配分の文脈におけるファクターモデルの先行研究を概観する。株式市場の分析に用いられるファクターモデルの多くはファクターリターンもしくはファクターローディングのどちらか一方を既知とした上でもう一方を推定する。それに対して、マルチアセット市場 (multi-asset market) の分析に用いられるファクターモデルはファクターリターン及びファクターローディングをどちらも未知とすることが多く、その推定手法としては主成分分析が広く用いられている [2] [3] [16]。マルチアセット市場を説明するリスクファクターはマクロ経済的な概念と紐づけて解釈されることが多く、マクロファクターとも呼ばれる。例えば、Bhansali et al. は構成されたリスクファクターを経済成長及びインフレーションと紐づけて解釈し [3]、伊藤・中川は経済成長、実質金利、インフレーションと紐づけて解釈した [16]。リスクファクターをマクロ経済的な概念と紐づけて解釈することは、リスクファクターを介して資産配分を決定する戦略において重要である。資産配分戦略として Factor Risk Budgeting 戦略を採用するファンドマネージャーは、自身が持つ市場見通しに基づいて各リスクファクターに対するリスク配分比率を決定する。そのため、リスクファクターはマクロ経済的な概念をはじめとする、一般的な市場見通しと関連する概念と紐づいて解釈されている必要がある。例え

*連絡先：野村アセットマネジメント株式会社

〒135-0061 東京都江東区豊洲二丁目2番1号

E-mail: shuhei.mi.st@gmail.com

本稿の内容は筆者らに属し、所属する組織としての見解を示すものではない。また、本稿にあり得べき誤りは全て筆者らに帰属する。

ば、景気拡大、金利低下を市場見通しとして持つファン
ドマネージャーは、経済成長に対応すると解釈した
リスクファクターに対して正の、実質金利に対応する
と解釈したリスクファクターに対して負のエクスポ
ージャーを取得するよう、リスク配分比率を決定する。

1.1 本稿で用いる記法

正整数 $N, T, K \in \mathbb{Z}_{>0}$ をそれぞれ分析対象となる資
産の数、観測されたリターンのサンプル数、ファクター
モデルにおいて採用するリスクファクターの本数とす
る。 $R \in \mathbb{R}^{T \times N}$, $F \in \mathbb{R}^{T \times K}$, $V \in \mathbb{R}^{N \times K}$, $E \in \mathbb{R}^{T \times N}$ を
それぞれ各資産のリターン、ファクターリターン、ファ
クターローディング、残差リターンが並んだ行列とす
る。以上の記法を用いて、マルチファクターモデルは
次のように表現される：

$$\begin{cases} r_{ti} = \sum_{k \in [K]} f_{tk} v_{ik} + e_{ti} & (\text{成分表示}) \\ R = FV^\top + E & (\text{行列表示}). \end{cases}$$

I_K は K 次の単位行列を表す。 $\|\cdot\|_2$ は L_2 ノルムを表す。
行列ノルム $\|\cdot\|_F$, $\|\cdot\|_{1,1}$ はそれぞれ Frobenius ノルム,
 $L_{1,1}$ ノルム¹を表す。関数 $\sigma_{\max}(\cdot)$ は行列を引数にとり、
その最大特異値を返す関数を表す。関数 $\text{ColScale}(\cdot)$ は
各列ベクトルが零ベクトルでない行列を引数にとり、そ
の各列ベクトルを L_2 ノルムが 1 となるように尺度化
した行列を返す関数を表す²。関数 $\text{diag}(\cdot)$ は正行列
を引数にとり、その対角成分を並べたベクトルを返す
関数を表す³。関数 $\text{prox}(\cdot|\cdot)$ は近接写像 [11] を表す⁴。

1.2 データセット

本稿では 7 つのアセットクラスに大別される 95 資
産を分析対象とする。ここで、7 つのアセットクラス
とは通貨、国債、社債、株式の 4 つのアセットクラス
に、農畜産物、エネルギー、金属の 3 つの商品カテ
ゴリーを加えたものを指す。表 1 は本稿で分析対象と
する 95 資産の内、商品を除く 71 資産に関して、本稿
における呼称をアセットクラス及び帰属する国・地域別
にまとめたものである。表 2 はこれら 71 資産のリター
ンを計算するために使用する指数及び各資産の呼称に
関する命名規則をまとめたものである。表 3 は本稿で
分析対象とする 24 の商品指数を商品カテゴリー別にま
とめたものである。リターンには金曜引け週次リター
ンを採用し、各資産のリターン $r_i \in \mathbb{R}^T$ はその L_2 ノ

ルムが 1 となるように尺度化する。また、リターンの
計測期間は 2015 年 1 月 2 日から 2019 年 12 月 27 日ま
での約 5 年間とする。従って、分析対象となる資産の
数 N 、観測されたリターンのサンプル数 T はそれぞれ
 $N = 95$, $T = 260$ を満たす。

2 次元削減手法

本章では代表的なリスクファクター構成手法である
主成分分析及びスパース主成分分析という 2 つの次元
削減手法を概観し、両者を対比させる形でその特徴と
問題点を整理する。

2.1 主成分分析

主成分分析（以下、PCA）は最も代表的な次元削減
手法であり、次の最適化問題を解くことによってファ
クターを構成する [1]：

$$\begin{aligned} & \underset{F, G, V}{\text{minimizing}} && \frac{1}{2} \|R - FV^\top\|_F^2 \\ & \text{subject to} && F = RG \\ & && G^\top G = I_K \\ & && V^\top V = I_K. \end{aligned}$$

目的関数はリスクファクターによって各資産のリター
ンを近似した際の残差平方和となっており、ファクター
を構成する問題として自然な設定となっている。また、
本最適化問題には、ファクターリターン $f_k \in \mathbb{R}^T$ が、
各資産のリターン $r_i \in \mathbb{R}^T$ の線形結合として $F = RG$
と表されるという制約が課せられている。これは、ファ
クターリターンを複製するポートフォリオのウェイト
を明示的に求めることに対応している。そこで、本稿で
はこのような行列 $G \in \mathbb{R}^{N \times K}$ を複製ウェイトと呼ぶ⁵。
本最適化問題の大域的最適解 (F^*, G^*, V^*) は $G^* = V^*$
を満たす [1]。また、 G^*, V^* は、 $R^\top R \in \mathbb{R}^{N \times N}$ の固有
ベクトルのうち、対応する固有値に関する上位 K 本を
その列ベクトルに持つ行列となる [1]。

PCA の問題点として、上位数本のリスクファクター
を除いて、構成されたリスクファクターを解釈するこ
とが難しいという点が挙げられる。先行研究において
も、PCA によって構成されたリスクファクターのうち、
解釈が与えられているものは上位数本に限られる [2] [3]
[16]。図 1 は第 1.2 節で導入したマルチアセット市場デー
タに対して PCA を適用することで構成された第 10 リ
スクファクターのファクターローディング $v_{10} \in \mathbb{R}^N$ を
示したものである。ローディングは各アセットクラス

¹ $\|R\|_{1,1} = \sum_{t \in [T]} \sum_{i \in [N]} |r_{ti}|$

² $\text{ColScale}(V) = \left[\frac{1}{\|v_1\|_2} v_1 \cdots \frac{1}{\|v_K\|_2} v_K \right]$

³ $\text{diag}(D) = [d_{11} \cdots d_{KK}]^\top$

⁴ $\text{prox}\left(V \left| a \|\cdot\|_{1,1} \right. \right) = \underset{V'}{\text{argmin}} \left\{ a \|V'\|_{1,1} + \frac{1}{2} \|V' - V\|_F^2 \right\}$

⁵ 一般的な名称でないことに注意されたい。Erichson et al. はこ
れを “weight matrix” と呼んでいる [6]。

表 1: 本稿における各指数の呼称

	国																						地域		
	DE	FR	IT	NL	ES	GB	CH	SE	ZA	JP	AU	HK	KR	SG	TH	IN	RU	TW	CN	US	CA	BR	DM	EM	EU
通貨	EUR					GBP	CHF	SEK	ZAR	JPY	AUD	HKD	KRW	SGD	THB	INR	RUB	TWD	CNY	-	CAD	BRL	-	-	-
国債	DE02Y	FR10Y	IT02Y	-	-	GB10Y	-	-	-	JP10Y	AU03Y	-	-	-	-	-	-	-	-	US02Y	CA10Y	-	-	-	-
	DE05Y		IT10Y								US05Y														
	DE10Y										US10Y														
	DE30Y										US20Y														
社債	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
																				US-Ind					EU-Ind
																				US-Utl					EU-Utl
																				US-Fin					EU-Fin
株式	DE	FR	IT	NL	ES	GB	CH	SE	ZA	JP-TOPIX	AU	HK	KR	SG	TH	IN	RU	TW	CN-HSCEI	US-SP500	CA	BR	DM-ExUS	EM	EU-Large
										JP-NK225									CN-A50	US-Dow					EU-Small
																				US-NASDAQ					

表 2: 各資産のリターンを計算するために使用する指数及び各資産の呼称に関する命名規則

アセットクラス	使用する指数	呼称の命名規則
通貨	対米国ドルのスポットレート	通貨コード
国債	限月のロールを考慮した先物のリターン指数	受渡適格債の発行国及び残存年数
社債（投資適格社債）	現物のリターン指数	発行体企業が帰属する国・地域及びセクター
社債（ハイイールド債）	現物のリターン指数	発行体企業が帰属する国・地域
株式	限月のロールを考慮した先物のリターン指数	帰属する国・地域 ただし、同一国に帰属する指数を複数採用する場合はその名称を追記

表 3: 商品指数の呼称

カテゴリー	本稿における呼称		
農畜産物	ChiWheat	Coffee	LeanHogs
	KanWheat	Sugar	LiveCattle
	Corn	Cocoa	FeederCattle
	Soybeans	Cotton	
エネルギー	CrudeOil	RBOB-Gasoline	Gasoil
	HeatingOil	BrentCrudeOil	NaturalGas
金属	Aluminium	Lead	Gold
	Copper	Zinc	Silver
	Nickel		

内で正負が入り混じる複雑な形状をしており、また、0成分を持つなど構造的な特徴もないため、このようなリスクファクターをマクロ経済的な概念と紐づけて解釈することは容易ではない。しかし、マルチアセット市場において Factor Risk Budgeting 戦略を運用するファンドマネージャーは、解釈を与えることができるリスクファクターが多ければ多い程、リスクファクターへのリスク配分比率を通じて自身の市場見通しをより精緻にポートフォリオに反映することが可能になるため、解釈可能なリスクファクターが少ないという PCA の性質は実務上重大な問題である。

2.2 スパース主成分分析

前節で示した PCA の問題点を解決する次元削減手法にスパース主成分分析（以下、SPCA）がある [15] [6]。PCA と同様に、SPCA はファクターリターン $f_k \in \mathbb{R}^T$

が各資産のリターン $r_i \in \mathbb{R}^T$ の線形結合で表されるという制約のもと、残差平方和を最小化する次の最適化問題を解くことによってファクターを構成する：

$$\begin{aligned} & \underset{F, G, V}{\text{minimizing}} && \frac{1}{2} \|R - FV^\top\|_F^2 + \lambda \|G\|_{1,1} \\ & \text{subject to} && F = RG \\ & && V^\top V = I_K. \end{aligned}$$

PCA との相違点は、SPCA では目的関数に複製ウェイト G に関する ℓ_1 正則化項が加えられている点である。 ℓ_1 正則化によって、SPCA によって構成される複製ウェイト G はスパースな、すなわち、多くの 0 成分を持つ行列となる。従って、各リスクファクターのファクターリターンを複製するポートフォリオは比較的少数の資産から構成されることになり、リスクファクターの解釈が容易となることが期待される。図 2 は第 1.2 節で導入したマルチアセット市場データに対して SPCA を適用することで構成された第 1、第 2 リスクファクターの複製ウェイト $g_1, g_2 \in \mathbb{R}^N$ を示したものである⁶。第 1 リスクファクターは主に各国の株式に対して、第 2 リスクファクターは主に各国の国債及び米国の投資適格社債に対して、それぞれ非 0 のウェイトを持つため、前者は国際的な経済成長期待、後者は国際的な金融緩和期待に対応するリスクファクターであると解釈することができる⁷。なお、本稿では紙面の都合により第 1、第 2 リスクファクターの複製ウェイトのみを示したが、第

⁶ ハイパーパラメータ K, λ はそれぞれ $K = 10, \lambda = 3 \frac{\sigma_{\max}(R)^2}{NK}$ と設定した。

⁷ 第 1 リスクファクターの解釈は [3] [16] と同一であり、第 2 リスクファクターの解釈は [2] と同一である。




図 1: PCA によって構成された第 10 リスクファクターのファクターローディング v_{10}

3 から第 10 リスクファクターも第 1, 第 2 リスクファクターと同様に非 0 の複製ウェイトが特定のアセットクラスに集中しており, 容易に解釈を与えることができる⁸.

一方、SPCA には次に掲げる 2 つの問題点が存在する。一点目は、上述の優位性の裏返しである。非 0 の複製ウェイトが特定のアセットクラスに集中することはリスクファクターの解釈性を向上させるが、その一方で各資産のリスクの源泉を分散させるという Meucci や Bhansali が提案した戦略 [10] [2] と矛盾する。二点目は SPCA によって構成されたファクターリターン同士が相関を持つという点である。表 4 は第 1.2 節で導入したマルチアセット市場データに対して SPCA を適用することで構成されたファクターリターンに関して、その相関係数の絶対値をまとめたものである。SPCA

表 4: SPCA によって構成されたファクターリターンの相関係数の絶対値

	1	2	3	4	5	6	7	8	9	10
Fac1	1.00									
Fac2	0.33	1.00								
Fac3	0.46	0.06	1.00							
Fac4	0.39	0.20	0.36	1.00						
Fac5	0.41	0.31	0.21	0.11	1.00					
Fac6	0.00	0.18	0.50	0.18	0.19	1.00				
Fac7	0.44	0.19	0.53	0.32	0.04	0.28	1.00			
Fac8	0.08	0.20	0.17	0.08	0.11	0.15	0.13	1.00		
Fac9	0.30	0.08	0.07	0.02	0.36	0.08	0.03	0.16	1.00	
Fac10	0.25	0.10	0.15	0.09	0.03	0.10	0.16	0.08	0.02	1.00

によって構成されたファクターリターンは45ペア中11ペアの相関係数の絶対値が0.3を上回り、中には0.53を示す組も存在する。しかし、ファクターリターンが互いに直交するもでは、構成したリスクファクターをポートフォリオのリスク管理や要因分解に活用することができる⁹ため、ファクターリターンが互いに直交することは実務上望ましい性質である。

⁸具体的には、第3リスクファクターから順に通貨及び新興国株式、石油関連商品、欧州社債指数、欧州各国の通貨、工業用金属、農産物、イタリア国債及びイタリア株式、畜産物にそれぞれ非0の複製ウェイトが集中した。

⁹これは、ファクターリターンが互いに直交するもとは、資産及びポートフォリオのリスクを各リスクファクターに起因するリスクに分解することができるという性質に基づく。この性質は次のように示すことができる。 $w \in \mathbb{R}^N$ をポートフォリオのウェイトと

3 提案手法

以上の先行研究を踏まえ、本章では PCA と比較してより多くのリスクファクターに対して解釈を与えることが可能であり、ファクターリターンが互いに直交するという、PCA 及び SPCA の問題点を同時に解決するリスクファクター構成手法を提案する。PCA 及び SPAC と同様、本手法に対応する最適化問題を残差平方和最小化問題として次のように定式化する：

$$\begin{aligned} & \underset{F, V}{\text{minimizing}} && \frac{1}{2} \|R - FV^\top\|_F^2 + \lambda \|V\|_{1,1} \\ & \text{subject to} && f_k^\top f_{k'} = 0 \quad (k, k' \in [K], k \neq k') \\ & && \|v_k\|_2 = 1 \quad (k \in [K]). \end{aligned}$$

PCA 及び SPCA との相違点は次の三点である．一点目は l_1 正則化を施す変数である．SPCA が複製ウェイト行列 G に対して l_1 正則化を施しているのに対し，提案手法ではファクターローディング V に対して l_1 正則化を施した． l_1 正則化によって，提案手法によって構成されるファクターローディング V は多くの 0 成分を持つ行列となる．従って，各リスクファクターは比較的少数の資産に対してその価格変動を説明することになり，リスクファクターの解釈が容易となることが期待される．二点目はファクターリターン F に課される制約である．PCA 及び SPCA が複製ウェイト G の存在を仮定し， $F = RG$ なる制約を課しているのに対し，提案手法はファクターリターン F が互いに直交するという制約のみを課している．三点目はファクターローディング V に関する制約である．提案手法ではファクターローディング V の各列ベクトルに関して，その L_2 ノルムを 1 に制約している．これは，ファクターリターン F 及びファクターローディング V の尺度に関する不定性を取り除き，ファクターローディング V の解をス

すれば、ポートフォリオのリターンを並べたベクトル $r_P \in \mathbb{R}^T$ は $r_P = R w$ を満たす。従って、ポートフォリオの推定リスク σ_P を $\sigma_P \stackrel{\text{def}}{=} \sqrt{\frac{1}{T-1} r_P^\top r_P}$ と定めれば、ファクターリターンが互いに直交するとき、ポートフォリオの推定リスク σ_P は次式を満たす：

$$\begin{aligned} (T-1) \cdot \sigma_{\mathbf{P}}^2 &= w^\top R^\top R w \simeq w^\top V F^\top F V^\top w \\ &= \sum_{k \in [K]} \|f_k\|_2^2 \cdot \left(v_k^\top w\right)^2. \end{aligned}$$




図 2: SPCA によって構成された第 1, 2 リスクファクターの複製ウェイト g_1, g_2

パースなものとするために導入したものである¹⁰。

3.1 求解アルゴリズム

本節では提案手法に対応する残差平方和最小化問題を求解するためのアルゴリズムを提案する。まず、ファクターリターンに対応する変数 F を、直交行列 $U \in \mathbb{R}^{T \times K}$ と対角行列 $D \in \mathbb{R}^{K \times K}$ との積として $F = UD$ と分解し、 U, D, V を変数に持つ先の問題と等価な最適化問題を構成する：

$$\begin{aligned} & \underset{U, D, V}{\text{minimizing}} \quad \frac{1}{2} \|R - UDV^\top\|_F^2 + \lambda \|V\|_{1,1} \\ & \text{subject to} \quad U^\top U = I_K \\ & \quad \quad \quad D : \text{diagonal matrix} \\ & \quad \quad \quad \|v_k\|_2 = 1 \quad (k \in [K]). \end{aligned}$$

このような変形を施すことによって、変数 U, D は他の二変数を固定したもとの容易に大域的最適解を計算することができる。そこで、本研究ではこの性質を踏まえ、ブロック座標降下法 [14] のように変数 U, D, V をサイクリックに更新するアルゴリズムを提案する。本アルゴリズムを擬似コードを用いて要約したものが Algorithm 1 である。擬似コード中の非負整数 l は反復回数を表す。

以下では変数 U, D, V それぞれの更新アルゴリズムを詳説する。先に述べたように、変数 U, D は他の変数を定行列とみなしたとき、その大域的最適解を容易に求めることができる。そこで、変数 U, D の更新は自身を

¹⁰ 任意の非 0 実数 $a \in \mathbb{R} \setminus \{0\}$ に対して $\|R - FV^\top\|_F = \|R - (aF)(\frac{1}{a}V)^\top\|_F$ が成立するため、 V に関する L_2 ノルム制約を課さない場合、目的関数の第一項 $\frac{1}{2} \|R - FV^\top\|_F^2$ の値を一定に保ったまま、目的関数の第二項 $\lambda \|V\|_{1,1}$ をいくらでも小さくすることができる。従って、 L_2 ノルム制約を課さない場合、ファクターローディング V の各成分は 0 に収束し、ファクターリターン F の各成分は発散する。

Algorithm 1 Proposed Algorithm

Input: $R, \lambda, U_{(0)}, D_{(0)}, V_{(0)}$

$l \leftarrow 0$

repeat

$$U_{(l+1)} \leftarrow \underset{U \in \mathbb{R}^{T \times K}}{\text{argmin}} \left\{ \|R - U D_{(l)} V_{(l)}^\top\|_F^2 \mid U^\top U = I_K \right\}$$

$$D_{(l+1)} \leftarrow \underset{D \in \mathbb{R}^{K \times K}}{\text{argmin}} \left\{ \|R - U_{(l+1)} D V_{(l)}^\top\|_F^2 \mid D : \text{diagonal} \right\}$$

Calculate V^{tmp} by evaluating a proximal operator

$$V_{(l+1)} \leftarrow \text{ColScale}(V^{\text{tmp}})$$

$l \leftarrow l + 1$

until convergence

return $(U_{(l)}, D_{(l)}, V_{(l)})$

Algorithm 2 Solve Procrustes Problem

Input: $R, D_{(l)}, V_{(l)}$

$$\text{Output: } \underset{U \in \mathbb{R}^{T \times K}}{\text{argmin}} \left\{ \|R - U D_{(l)} V_{(l)}^\top\|_F^2 \mid U^\top U = I_K \right\}$$

$$B^{\text{tmp}} \leftarrow R V_{(l)} D_{(l)}$$

$$P \Sigma Q^\top \xleftarrow{\text{SVD}} B^{\text{tmp}}$$

return PQ^\top

唯一の変数とみなしたときの大域的最適解により行う。 U に関する残差平方和最小化問題は直交 Procrustes 問題 [7] と等価であるため、Algorithm 2 に示すように、行列積計算及び特異値分解によってその大域的最適解を計算することができる。また、 D を唯一の変数とみなしたとき、残差平方和 $\|R - U_{(l+1)} D V_{(l)}^\top\|_F^2$ は $\text{diag}(D)$ に関する凸二次関数であるため、その大域的最適解は次式となる：

$$\begin{aligned} & \underset{\text{diag}(D)}{\text{argmin}} \left\{ \|R - U_{(l+1)} D V_{(l)}^\top\|_F^2 \mid D : \text{diagonal} \right\} \\ & = \text{diag} \left(U_{(l+1)}^\top R V_{(l)} \right). \end{aligned}$$

最後に、 V の更新アルゴリズムを示す。 V の更新は次の二段階の手続きから成る。 一段階目の手続きでは近接勾配法 [11] における一反復、すなわち、次に示すような近接写像の評価を行う：

$$V^{\text{tmp}} \leftarrow \text{prox} \left(V_{(l)} - \frac{1}{\mu_{(l)}} \left(\frac{\partial}{\partial V} f_l(V_{(l)}) \right) \middle| \frac{\lambda}{\mu_{(l)}} \|\cdot\|_{1,1} \right).$$

ここで、関数 f_l は更新時点における残差平方和を、実数 $\mu_{(l)}$ は ∇f_l の Lipschitz 定数を表す¹¹。 $L_{1,1}$ ノルムに対応する近接写像の評価はソフト閾値処理と等価である [11]。 加えて、関数 f_l の勾配は解析的に表示することができる¹²ため、一段階目の手続きは行列計算及び比較演算のみによって達成できる。 二段階目の手続きではファクターローディングに課された制約を満たすため、一段階目の手続きによって得られた行列 V^{tmp} の各列ベクトルを L_2 ノルムが1となるように尺度化する。 本アルゴリズムの有効性は第4章で実験的に示す。

4 数値実験

本章では人工データ及びマルチアセット市場データを用いた数値実験によって提案手法の有効性を示す。

4.1 人工データ実験

本節では人工データを用いた数値実験によって提案手法の有効性を示す。 人工データの生成プロセスは次に掲げる二段階から成る。 一段階目ではファクターリターン F 、ファクターローディング V 、残差リターン E を表5に従って生成する。 続いて、二段階目では $FV^T + E$ なる計算を行い、これを観測されたリターン行列 R とする。 続いて、閾値処理というナイーブな考え方に基

表 5: 人工データの生成プロセス

生成する行列	各成分の生成	生成後の加工
ファクターリターン F	標準正規分布 $\mathcal{N}_1(0, 1^2)$	QR 分解を施すことで直交行列を構成する
ファクターローディング V	標準正規分布 $\mathcal{N}_1(0, 1^2)$	列ベクトルごとに次の操作を施す ・ 絶対値に関する下位 50% の成分を 0 置換 ・ L_2 ノルムが1となるように尺度化
残差リターン E	正規分布 $\mathcal{N}_1(0, 0.01^2)$	-

づくファクターローディング V の推定手法を本実験の

¹¹それぞれ次のようになる：

$$f_l(V) \stackrel{\text{def}}{=} \frac{1}{2} \|R - U_{(l+1)} D_{(l+1)} V^T\|_F^2$$

$$\mu_{(l)} = \max_{k \in [K]} \left\{ \left| [D_{(l+1)}]_{kk} \right|^2 \right\}.$$

¹² $\nabla f_l(V) = V D_{(l+1)}^2 - R^T U_{(l+1)} D_{(l+1)}$

ベースライン手法として導入する。 ベースライン手法は次に掲げる三段階の手続きから成る。

1. 生成されたリターン行列 R に対して PCA を適用する。
2. PCA によって構成されたファクターローディング V の成分のうち、その絶対値に関する下位 $100 \cdot Q\%$ を 0 置換する。ただし、各列ベクトルを非零ベクトルに保つため、各列ベクトルにおける絶対値が最大の成分に対しては 0 置換を行わない。従って、ハイパーパラメータ Q は $\frac{1}{NK}, \dots, \frac{(N-1)K}{NK}$ の値をとり得る。
3. 各列ベクトルをその L_2 ノルムが1となるように尺度化する。

本実験ではファクターローディングの各成分が0であることを陽性と定義し、ROC 曲線及び Area Under the Curve (以下、AUC) を計算する。 実験セットアップは下記の通りである。 資産数 N を 20、観測されたリターンのサンプル数 T を 1000、リスクファクターの本数 K を 3 とし、リターン行列 R は提案手法及びベースライン手法のハイパーパラメータ λ, Q ごとに 100 通り生成する。 図3は ROC 曲線を示したものである。 AUC は提案手法が 0.903、ベースライン手法が 0.785 となり、提案手法の有効性が示された。




図 3: 提案手法及びベースライン手法に対応する ROC 曲線

4.2 マルチアセット市場データ実験

本節では第1.2節で導入したマルチアセット市場データに対して提案手法を適用することで構成されたリスクファクターをマクロ経済的な観点から解釈する。 本稿では紙面の都合により、構成した 10 本のリスクファクターのうち、第4、第6、第7リスクファクターに対する解釈のみを記載する。 この選定理由は次の二点である。 一点目は、下位のリスクファクターを観察する




図 4: 提案手法によって構成された第 4, 第 6, 第 7 リスクファクターのファクターローディング v_4, v_6, v_7

ことによって、下位のリスクファクターを解釈することが難しいという PCA の問題点を提案手法が解決していることを示すためである。二点目は、これらのリスクファクターがそれぞれ貿易、金融政策、外交政策という、相異なるマクロ経済的な概念と紐づいて解釈されるという、示唆に富む結果となったためである¹³。

図 4 は提案手法によって構成された第 4, 第 6, 第 7 リスクファクターのファクターローディング v_4, v_6, v_7 を示したものである¹⁴。まず、第 4 リスクファクターを解釈する。当ファクターは石油関連商品、米国ハイイールド債券指数、カナダドル、ロシアルーブルに対して正のローディングを持つ。米国ハイイールド債券指数の構成銘柄は、時価総額ベースで 10% 以上がエネルギー関連企業をその発行体にもつため、石油需要の拡大はそうした企業の信用拡大、ひいては米国ハイイールド債券指数の上昇に寄与する。さらに、ロシア、カナダは世界有数の産油国であり、石油需要の拡大は石油関連商品の輸出拡大、ひいてはロシアルーブル高、カナダドル高の進行を促進する。従って、当ファクターは石油需要の拡大に対応すると解釈することができる。次に、第 6 リスクファクターを解釈する。当ファクターは欧州各国の国債、投資適格社債指数に対して正の、欧州各国の通貨に対して負のローディングを持つ。一般

に、自国通貨の金利低下によって国債及び投資適格社債は価格が上昇し、通貨は通貨安・ドル高が進行するため、当ファクターは欧州各国の中央銀行に対する緩和的な金融政策への期待に対応すると解釈することができる。最後に、第 7 リスクファクターを解釈する。当ファクターはイギリスポンド、欧州社債指数に対して正の、イギリス株式指数に対して負のローディングを持つ。Brexit の穏健化への期待、すなわち、イギリスが経済的な繋がりを保ったまま欧州連合を離脱することへの期待は、イギリス経済に対する不透明性の解消、ひいてはイギリスポンド高の進行や欧州社債指数の上昇を促進する。さらに、Brexit 穏健化への期待が高まることによるイギリスポンド高の進行はイギリスの外需型企業に嫌気され、イギリス株式指数の下落を促進する。従って、当ファクターは **Brexit 穏健化への期待**に対応すると解釈することができる。

最後に、提案手法によって構成されたリスクファクターの説明力を確認する。リスクファクターの寄与率を $1 - \frac{\|R - FV^T\|_F^2}{\|R\|_F^2}$ で定める。このとき、主成分分析及び提案手法によって構成されたリスクファクターの寄与率はそれぞれ 67.14%, 66.05% となった。提案手法によって構成されるリスクファクターはその解釈が容易である一方、説明力は主成分分析によって構成されるリスクファクターに劣る。しかし、毀損の程度は限定的であり、実用に足る水準である。

¹³ 第 5, 第 8, 第 9, 第 10 リスクファクターはそのファクターローディングがそれぞれ特定のアセットクラスや地域に集中しており、解釈が容易であったため本稿では割愛した。具体的には、それぞれ農産物、工業用金属、南欧各国に帰属する資産、畜産物に非 0 のローディングが集中した。

¹⁴ ハイパーパラメータ K, λ はそれぞれ $K = 10, \lambda = 3 \frac{\sigma_{\max}(R)^2}{N K}$ と設定し、Algorithm 1 の初期値 $U_{(0)}, D_{(0)}, V_{(0)}$ はリターン行列 R に特異値分解を施すことで構成した。

5 結論

本研究では解釈性とファクターリターンの直交性を両立するリスクファクター構成手法を提案し、その有効性を人工データ及びマルチアセット市場データを用いた実験によって示した。マルチアセット市場データを用いた実験では、提案手法によって構成されたマクロファクターが貿易、金融政策、外交政策など相異なるマクロ経済的な概念と紐づいて解釈され、提案手法の有効性が実証的に示された。

今後の課題としては、提案手法が持つハイパーパラメータを調整する手法や、局所収束性を持つ求解アルゴリズムを提案することが挙げられる。

謝辞

本稿の執筆にあたり、多くの知識や示唆を頂いた野村アセットマネジメント株式会社の大野一郎氏及び大本隆氏に感謝いたします。

参考文献

- [1] Hervé Abdi and Lynne J Williams. Principal component analysis. *Wiley interdisciplinary reviews: computational statistics*, Vol. 2, No. 4, pp. 433–459, 2010.
- [2] Vineer Bhansali. Beyond risk parity. *The Journal of Investing*, Vol. 20, No. 1, pp. 137–147, 2011.
- [3] Vineer Bhansali, Josh Davis, Graham Rennison, Jason Hsu, and Feifei Li. The risk in risk parity: A factor-based analysis of asset-based risk parity. *The Journal of Investing*, Vol. 21, No. 3, pp. 102–110, 2012.
- [4] Benjamin Bruder and Thierry Roncalli. Managing risk exposures using the risk budgeting approach. *Available at SSRN 2009778*, 2012.
- [5] Yves Choueifaty and Yves Coignard. Toward maximum diversification. *The Journal of Portfolio Management*, Vol. 35, No. 1, pp. 40–51, 2008.
- [6] N Benjamin Erichson, Peng Zheng, Krithika Manohar, Steven L Brunton, J Nathan Kutz, and Aleksandr Y Aravkin. Sparse principal component analysis via variable projection. *SIAM Journal on Applied Mathematics*, Vol. 80, No. 2, pp. 977–1002, 2020.
- [7] John C Gower. Generalized procrustes analysis. *Psychometrika*, Vol. 40, No. 1, pp. 33–51, 1975.
- [8] Sébastien Maillard, Thierry Roncalli, and Jérôme Teïletche. The properties of equally weighted risk contribution portfolios. *The Journal of Portfolio Management*, Vol. 36, No. 4, pp. 60–70, 2010.
- [9] Harry Markowitz. Portfolio selection. *Investment under Uncertainty*, 1959.
- [10] Attilio Meucci. Managing diversification. *Risk*, Vol. 22, No. 5, pp. 74–79, 2009.
- [11] Neal Parikh, Stephen Boyd, et al. Proximal algorithms. *Foundations and Trends® in Optimization*, Vol. 1, No. 3, pp. 127–239, 2014.
- [12] Edward Qian. Risk parity portfolios: Efficient portfolios through true diversification. *Panagora Asset Management*, 2005.
- [13] Thierry Roncalli and Guillaume Weisang. Risk parity portfolios with risk factors. *Quantitative Finance*, Vol. 16, No. 3, pp. 377–388, 2016.
- [14] Paul Tseng. Convergence of a block coordinate descent method for nondifferentiable minimization. *Journal of optimization theory and applications*, Vol. 109, No. 3, pp. 475–494, 2001.
- [15] Hui Zou, Trevor Hastie, and Robert Tibshirani. Sparse principal component analysis. *Journal of computational and graphical statistics*, Vol. 15, No. 2, pp. 265–286, 2006.
- [16] 伊藤 彰朗・中川 慧. マクロファクターの定量化とリスク分析への活用. 証券アナリストジャーナル, Vol. 56, No. 8, pp. 80–90, 2018.

評価関数の可視化による株価予測モデルの汎用性評価 Versatility Evaluation of Stock Prediction Model by Visualization of Cost Function

坂下好希^{1*} 瀬之口潤輔²

Yoshiki Sakashita¹ and Junsuke Senoguchi²

¹ 東京大学 経済学研究科

¹ Graduate School of Economics, The University of Tokyo

² 東京工科大学 コンピュータサイエンス学部

² School of Computer Science, Tokyo University of Technology

Abstract: When predicting stock prices with a complex model using machine learning or artificial intelligence, overfitting sometimes occurs, and the prediction accuracy expected in actual operation cannot be obtained. In such a model, the cost function is presumed to be steep and multi-modal, while in a model that maintains stable prediction results, the cost function is considered to be gradual and single-peaked. In this study, we first compared the performance of several stock price prediction models, and then visualized the cost function for each model using t-SNE. As a result, the model using Lasso regression, which had the highest performance, showed a gradual unimodal cost function, while the linear regression, which had relatively low performance, showed a steep and multi-modal shape. Visualizing the cost function using t-SNE can be an important index for evaluating the stability and versatility of a stock price prediction model.

Keywords: t-SNE, cost function, visualization, versatility evaluation, wavelet, reducing dimension

1. はじめに

株価予測は多くの研究者や実務家によって行われている研究領域である。近年では伝統的な統計手法に加えて機械学習や人工知能を用いて、複雑なモデルを構築し株価予測を行う研究も多い。実務でも、人工知能により株価判断を行い、資金を運用する投資信託が登場している。しかし機械学習等を用いた複雑なモデルにより株価が予測可能かについては、依然として結論は出ていない。株価予測モデルに頻繁にみられる問題として、訓練時では高い予測精度を示す一方で、実際に運用では期待されていた予測精度が得られないことである。これには複雑なモデルを構築することにより訓練データのノイズ等まで学習してしまうオーバーフィッティングが要因となっていることがある。

特に株価のように様々な非継続的な要因により変動する対象をモデル化する場合、パラ

メータの数を増やし複雑なモデルで訓練データを学習すると、最適なパラメータによる学習データの評価値は高いものの、非継続的なノイズまで学習している可能性から、その周辺のパラメータを用いた評価値は大幅に悪くなることもある[1]。パラメータの最適値からわずかに変化するだけで、評価値が大きく悪化するという事は、最適モデルにおいて訓練データがわずかに変化するだけで評価値が大きく悪化することにもなる。つまりモデルに汎用性が乏しいことを意味する。このようなモデルを用いて将来を予測しても、十分に高い予測精度を示すことができないと考えられる(図 1a)。

一方で最適なパラメータから多少離れても評価値が大きく変わらない、つまり評価関数のグラフが比較的なだらかなモデルであった場合、訓練データが多少変わっても評価値は大きく変化せず、モデルに汎用性が高いことを意味する。このようなモデルを用いて将来を予測した場合、比較的高い予測精度を示す

* 連絡先:sakashita1519@gmail.com

ことができると考えられる (図 1b)。




図 1a：評価関数の形状とモデルの汎用性：急峻な多峰性の場合




図 1b：評価関数の形状とモデルの汎用性：緩やかな単峰性の場合

このように評価関数を可視化してモデルの構造を解明することは、モデルの安定性・汎用性を評価するうえで極めて重要である。しかしパラメータが高次元である場合、評価関数も非常に複雑な形状となり、人間がそれを直接的に理解することは極めて困難である。

本研究では、線形モデルを用いて汎用性評価の手法を検討し、評価関数を投資戦略の累積リターンとして、偏回帰係数をパラメータと見なして変化させたときにリターンがどのように変化するかを確認する。最適なパラメータ付近で緩やかで単峰性がある評価関数だと汎用性があるモデルだと定義する。また、高次元空間におけるデータ間の関係性やデータの特徴を保持したまま、低次元空間にマッ

ピングする手法である t-SNE (t-Distributed Stochastic Neighbor Embedding)を用いて、高次元モデルの評価関数を可視化し、その形状がなだらかな単峰性であればモデルの安定性・汎用性が高く、結果としてある一定期間だけではなく長期間にわたり運用成績が安定する株価予測モデルを作成することができると考えられる。

2. 先行研究

株価予測モデルの精度を証明するためには、モデルの構造を解明してモデルの汎化性が高いことを確かめることが重要である。モデル構造の解明には、高次元データを次元圧縮し可視化することが大いに役立つ。

高次元データの次元圧縮とその可視化は、機械学習やデータマイニングの分野において古くから非常に重要な問題であり、これまでに多くの手法が開発されてきた。次元圧縮の代表的な手法である主成分分析は[2]により導入され、可視化手法として[3]による Multidimensional scaling が開発された。

高次元空間上でデータが同一の非線形多様体上に存在する場合、線形の次元圧縮手法ではマッピング先の低次元区間上において、それらのデータを類似しているものとして表現することができない。このため 2000 年代初頭には非線形の次元圧縮法が次々に開発され、代表的なものとして[4]の IsoMap, [5]の Locally Linear Embedding, [6]の Laplacian Eigenmaps などがある。

しかし多くの非線形次元圧縮手法は人工データには有効であるが、実データに対しては精度が著しく低下するという欠点があった。

[7]はこの問題を解決する手法として、t-SNE の開発を行った。t-SNE は、人工データだけでなく複雑な実データに対しても有効であり、かつより高次元のデータに対しても適切に機能することが示されている。

3. データと分析手法

3.1 分析に用いたデータ

目的変数として、期近の TOPIX 先物の翌日始値 (8:45) から終値 (15:15) のリターンを用いる。説明変数として、表 1 に示した金融指標を用いた。変数 No.1~No.7 からウェーブレット変換により各レベルのウェーブレット係数を抽出する。ウェーブレット係数のレベルは 1~3 とする。つまりサポート期間が 2 営業日、

項目番号	項目名	基準	単位
No.1	TOPIX (東証株価指数)	前日東京終値～当日東京終値	変化率
No.2	S&P 500種	前日NY終値～当日NY終値	変化率
No.3	S&P 500のロス指数	前日NY終値～当日NY終値	対S&P相対変化率
No.4	S&P 中型株400種	前日NY終値～当日NY終値	対S&P相対変化率
No.5	CBOE SPXボラティリティ指数	前日NY終値～当日NY終値	変化幅
No.6	米ドル/円	前日NY終値～当日NY終値	変化率
No.7	TOPIX過去20日移動平均からの乖離	当日東京終値	水準
No.8	TOPIX14日RSI	当日東京終値	水準
No.9	14日RSIが70を上回っているTOPIX構成銘柄の割合	当日東京終値	水準
No.10	14日RSIが30を下回っているTOPIX構成銘柄の割合	当日東京終値	水準

表 1：分析に使用する金融指数

4 営業日, 8 営業日とする。ウェーブレットフィルタはハールウェーブレットを使用する。それらに 4 種類のテクニカル指標を加えた 25 種類の指標を説明変数として採用する。

3.2 モデルの予測精度の評価方法

本研究では線形モデルを用いた投資戦略構築やモデル評価を行うが、このモデルによる投資戦略構築には 2 点の問題がある。

1 点目は偏回帰係数の推定方法である。重回帰分析や Lasso 回帰の偏回帰係数は最小二乗誤差(評価関数)やそれに正則化項を足し合わせた損失関数を最小化するように推定される。しかし、重要なのはテストでの投資リターンの大きさであり、損失関数によって求められた偏回帰係数が最も投資成績が良いとは限らない。

2 点目は評価関数の形状である。累積リターンを評価関数とすると、単峰性でなく山が複数ある可能性が生じる(図 1a のような多峰性)。また、山のなだらかであれば偏回帰係数が多少変化しても投資パフォーマンスは大きく落ちないが、山が急峻だと急激に悪化する(図 1b)。そのため、評価関数の値だけでなく、形状にも注目する必要がある。しかし本研究では偏回帰係数をパラメータとして扱うが、これは高次元であり、人間が評価関数の形状を把握するのは難しい。

本研究では、線形モデルで構築した投資戦略の汎用性評価の手法を検討し、評価関数を投資戦略の累積リターンとして、偏回帰係数をパラメータと見なして変化させたときに評価関数(累積リターン)がどのように変化するかを確認する。また評価関数の山の形状把握の難しさを解決するために、高次元空間におけるデータ間の関係性やデータの特徴を保

持したまま、低次元空間にマッピングする手法である t-SNE (t-Distributed Stochastic Neighbor Embedding)を用いて次元削減して、高次元モデルの評価関数を可視化する。

モデルの評価に関しては、次元削減された評価関数が損失関数で推定されたパラメータ付近で緩やかに単峰性があると汎用性があるモデルだとする。その形状がなだらかな単峰性であればモデルの安定性・汎用性が高く、結果としてある一定期間だけではなく長期間にわたり運用成績が安定する株価予測モデルを作成できると考えられる。

ここから具体的な分析方法について説明していく。

本研究では、モデルの評価関数として、walk forward test による累積リターンを採用する。walk forward test では、予測を行う当日まで T 日分の訓練データを用いてモデルを学習して、翌日の予測値を算出する。予測は翌日分だけ行う。1 日ずらして同様の操作を中長期にわたり繰り返していく。この手法を採用した理由は、毎日モデルを作り直していくので、株式市場の局面が変化したとしてもモデルがそれに対応するため、モデルが陳腐化しにくいことである。また回帰モデルの回帰係数の時間変化を確認できるため、株価予測モデルの構造変化を確認できるメリットもある。

T に関しては、[8]が 2500 日分の株価データ、[9]が約 1600 日分のデータでそれぞれモデルを学習させていたことを参考に、この 2 つの中間値に近い 2000 日とした。

説明変数と目的変数はそれぞれ標準化してモデルを学習させ、翌日の標準化された予測値を計算する。得られた予測値に標準化の逆の操作を行い、これを翌日のリターン予測値とする。モデルは Lasso 回帰($\alpha=0.01$)、Ridge 回帰($\alpha=10$)、Elastic Net 回帰($\alpha=0.01, p=0.5$)、正則

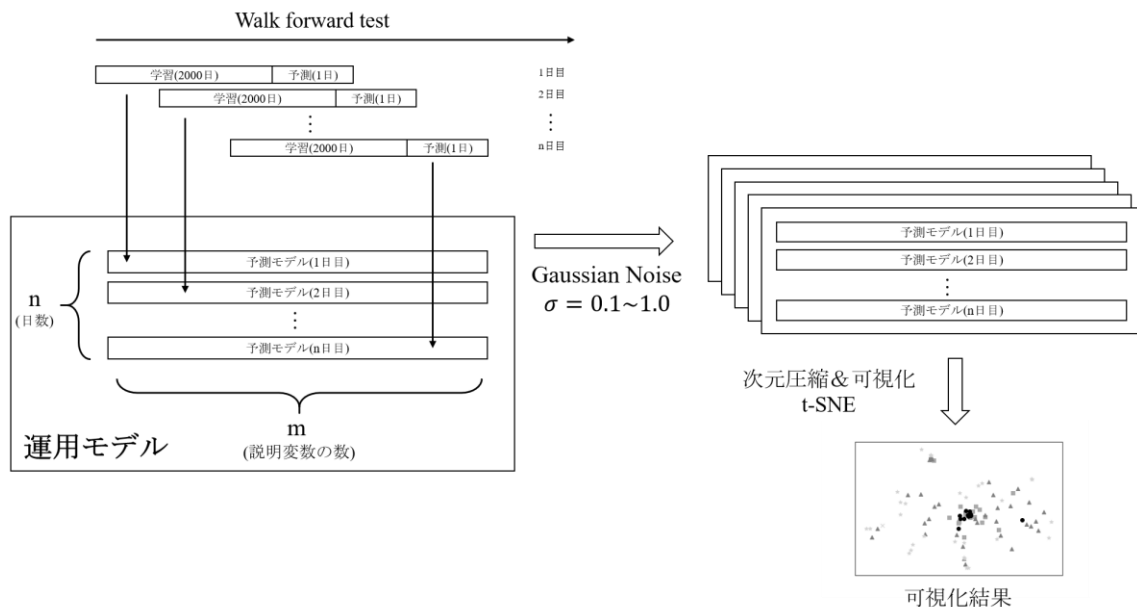


図 2：モデルの安定性の評価方法

化項を用いない重回帰分析（Linear 回帰）の 4 種類を用いる。

4 種類それぞれのモデルで、予測精度の評価を行う。具体的には、翌日のリターン予測値が正であれば TOPIX 先物を翌日の寄付き（始値）で買い、引け（終値）で売る。負であれば翌日の寄付き（始値）で売り、引け（終値）で買い戻す。これを walk forward test の全期間で繰り返す。walk forward test により翌日のリターン予測を行う期間は 2001 年 9 月 10 日から 2019 年 2 月 13 日までとする。つまり 4,274 回の予想を行い、その成績に基づきモデルを評価する。

2001 年 9 月 10 日運用前の資産を 1 として、上記のルールに基づいて複利で運用する。2019 年 2 月 13 日時点の資産を株価予測モデルの累積リターンとし、これを株価予測モデルの予測精度の評価基準とする。

評価の基準は、(1) 4,274 回の騰落予測の正解率 (acc)、(2) 4,274 回のうち翌日のリターンの絶対値が 2% 以上のとき騰落予測の正解率 (acc_2%)、(3) 4,274 個の株価予想と実績に関する平均平方二乗誤差 (RMSE)、(4) 2001 年 9 月 10 日運用前の資産を 1 として、上記のルールに基づいて複利で運用した場合の累積リターン (cum_r) の 4 つとする。

3.3 モデルの安定性の評価手法

本研究では、予測精度の高い株価予測モデルを作成するだけでなく、株価予測モデ

ルの安定性・汎用性の評価も行う。

本研究で用いるモデルは翌日の株価騰落を予測するものであり、短期的な時系列データ予測を検証しているといえる。しかしながら、株価予測においては株価のランダムネスや突発的な変動により、必ずしもある一定期間の短期的な予測精度が中長期的な累積リターンにつながるわけではないということが明らかとなっている。そこで我々は、本研究でモデルの精度の評価基準となっている中長期的な累積リターンに注目して、モデルの安定性・汎用性を検証する。

モデルの安定性・汎用性を評価する手法を図 3 に示す。本研究では walk forward test により、1 日ごとに翌日の株価を予測するためのモデルを獲得することができる（これを「予測モデル」と呼ぶ）。そして、その 1 日ごとの予測モデルを用いて、 n 日間運用した時に得られるモデルを「運用モデル」とする。このとき、予測モデル学習における説明変数の数を m とすると、運用モデルのパラメータは $n \times m$ 個のマトリックスとして与えられる。このようにして得られた運用モデルの $n \times m$ 個のパラメータにそれぞれ異なるガウシアンノイズ（標準偏差=0~0.1）を与え、ノイズ付きの運用モデルによる累積リターンにより、モデルの安定性・汎用性を評価する。つまりモデルの費用関数が最適値付近でなだらかな単峰性の特徴を有していれば、パラメータが多少変化しても累




図3：各モデルの累積リターンの推移

積リターンはさほど変化しない.このような安定した費用関数を持つモデルは,市場環境が変わったとしても安定した予想精度を維持することができ,汎用性が高いと言える.一方で費用関数が急峻で多峰性なものである場合,パラメータの値が最適値から多少ずれるだけで累積リターンは急激に悪化する.このような費用関数を持つモデルは汎用性が低いと言える.これらのことから,運用モデルのパラメータにノイズを加えたときの累積リターンの大きさと変動係数を,モデルの安定性・汎用性を評価する指標として用いる.

更に, t-SNE を用いて運用モデルを 2 次元空間に圧縮することによって,運用モデルと累積リターンとの間の関係性について調べる.本評価では,異なるノイズを付与した運用モデル ($n \times m$) を k 個作成する,そして, k 個のモデルに対して t-SNE を施すことにより 2 次元空間に描画する.つまり, k 個の運用モデル を 2 次元空間 (R^2) にマッピングするのである.更に,それぞれの運用モデルによる累積リターンと t-SNE によって描画された 2 次元空間での距離から,累積リターンと運用モデルの関係性について議論する.

4. 分析結果

4.1 モデルの予測精度の評価結果

表 2 に各モデルの予測精度の一覧を示す.予測精度の評価方法は,4.2 で示した 4 つの基準を用いた.

Lasso 回帰がいずれの指標においても,最も高いパフォーマンスとなっている.次いで, Elastic Net 回帰のパフォーマンスが高く, Ridge 回帰と正則化項を用いない重回

帰分析 (Linear 回帰) はいずれの指標においてもパフォーマンスが劣っていた.正則化項を用いることで精度が高まり,特に L1 正則化項による次元圧縮がモデルのパフォーマンスを改善させていることが確認された.

	acc	acc_2%	RMSE	cum_r
Lasso	51.8%	58.4%	0.01022	40.1
Ridge	51.1%	55.9%	0.01026	17.6
Elastic Net	51.2%	57.7%	0.01023	25.7
Linear	51.1%	55.5%	0.01026	16.5

表 2：各モデルの精度

図 3 に各モデルで walk forward test を行ったときの累積リターンの推移を示す.ベンチマークとして TOPIX の推移も示した.いずれのモデルでも TOPIX をアウトパフォームしており,中でも Lasso 回帰のモデルは約 20 年間の walk forward test 期間で資産価値は約 40 倍となった.騰落予測の正解率が 51.8%と高くない水準で累積リターンが大きい理由は, acc_2%が 58.4%と高いためである.つまり本研究で作成した株価予測モデルは,安定性・汎用性を重視しているため,一過性の要因による株価の微小な変化を正確に予測することはできないが,一方で株価の大きな変化の要因になるような普遍的なコアの構造は概ね捉えており,これが walk forward test 全体の正解率が高くない一方で acc_2%が比較




図 4：ノイズ付与による累積リターンの変化




図 5：ノイズ付与時の累積リターンの変動

的高い理由となっている。

4.2 ノイズ付与によるモデルの安定性・汎用性の評価結果

図 4 は、運用モデルに与えるガウシアンノイズの標準偏差ごと (0~0.1) に、累積リターンを比較したものである。それぞれの標準偏差で異なるノイズの付与を 10 回行い、それから得られる 10 個の累積リターンの平均値を示している。Ridge 回帰と Linear 回帰は、いずれの標準偏差においても累積リターンは低い水準である。一方で Lasso 回帰と Elastic Net 回帰は、累積リターンの水準が比較的高く、またノイズ大きくなるに伴い累積リターンが低下していることがわかる。

図 5 は、図 4 の結果のもとになる 10 個の累積リターンの変動係数を示したものである。Lasso 回帰を用いた分析の変動係数が安定して低く推移していることがわかる。Elastic 回帰を用いた分析では、累積リターンは大きい、その安定性は低いことが示された。また、Ridge 回帰と Linear

を用いた分析では、累積リターンの水準が低いことに加えて変動係数も高く、予測精度および安定性ともに低いことが示された。

4.3 t-SNE を用いたモデルの安定性・汎用性の評価結果

図 6 は、ガウシアンノイズ (標準偏差=1) を加えた運用モデルを t-SNE を用いて 2 次元空間上に次元圧縮し、散布図として表したものである ((a) Lasso 回帰, (b) Elastic Net 回帰, (c) Ridge 回帰, (d) Linear 回帰)。次元圧縮の際の用いたパラメータはパープレキシティを 50、イテレーションを 1000 に設定した。各プロットはガウシアンノイズを付与した運用モデルを表しており、その総数は 100 である。また、プロットの形状はそれぞれの運用モデルを用いた際の累積リターンを表している (円：40 倍以上、四角形：30~40 倍、三角形：20~30 倍、星形：10~20 倍、×印：10 倍以下)。

図 6(a)では、中心部に累積リターンが 30

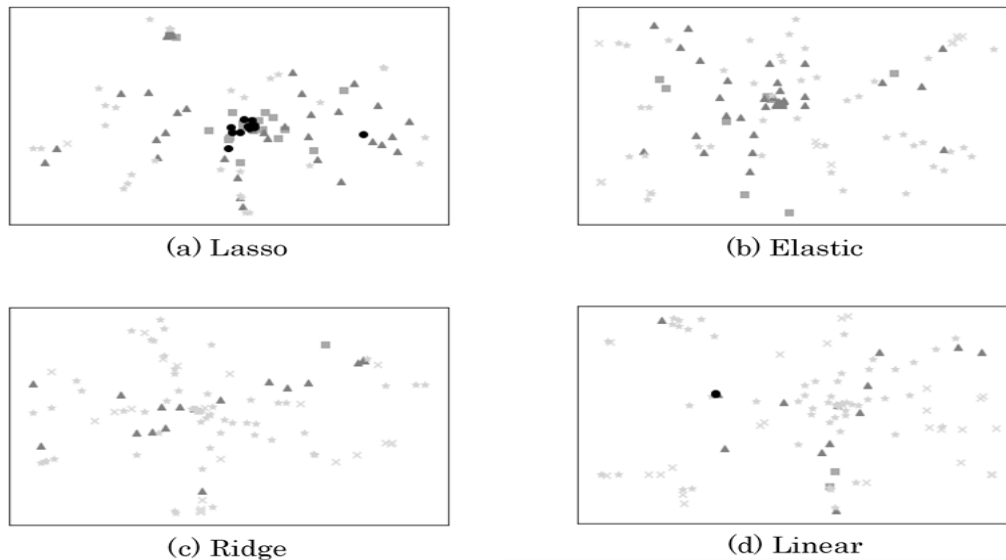


図 6 : t-SME による可視化結果

倍以上の運用モデルが集まっており、中心は下がっていることがわかる。つまり、Lasso 回帰を用いたモデルでは、高次元空間におけるモデルの類似性と累積リターンの大きさには相関があるといえる。一方、図 6(b), (c) と(d)では、次元圧縮後の各モデルの位置と累積リターンの間に明確な規則性は見られなかった。

5. 考察

本研究の目的は、長期間にわたり運用成績が安定している株価予測モデルを作成することに加えて、その構造を可視化し説明することにより、どのようなモデルが安定した運用成績を継続できるか、評価の指針を示すことである。

まず運用成績が安定している株価予想モデルの作成について、表 2 および図 3 から、正則化項を用いて次元圧縮を行うことが効果的であることが示された。株式市場では多数の参加者が価格形成に影響を与えるため、株価は短期間で乱高下することがあり、また金融環境は常に変化しているためこのような短期間の動きに影響を与える要因も一定とは限らない。このような株式市場の特性を多数のパラメータを用いた複雑なモデルで表現した場合、過去の一過性のノイズまで説明することによりモデルが過学習を起こしやすい。とくに金融市場のデータは過去の事象であるため複製ができず、データ数の制約

から遠ざかっていくにつれて、累積リターンがある中で過学習の問題を回避するには、パラメータを重要なものに制限し株式市場のコアの構造を捉えるモデルを構築することが特に重要である。正則化項を用いて次元圧縮を行ったモデルの予測精度が高い結果となったのは、モデルがノイズを拾わずに、株式市場の普遍的なパターンを表現しているためと考えられる。

次に安定した運用成績を継続できるかについて、構築したモデルのすべてのパラメータに対してノイズを付与し運用成績がどの程度変化するかを計測することにより、モデルの汎用性と安定性を評価した。図 4 の結果から、Lasso 回帰を用いた手法はノイズの大きさに依存して累積リターンが変動しているものの、基本的に他の手法よりも高い累積リターンを得られることが分かった。また、累積リターンの大きさは、明らかに Lasso 回帰 > Elastic Net > Ridge 回帰 ≒ Linear 回帰となっている。本研究で用いた説明変数数は 24 であり、この程度の説明変数数では L1 正則化項を用いた学習が適していることが示された。

更に図 5 の結果から、Lasso 回帰を用いた手法は他の正則化を用いた手法に比較して、モデルに同じ標準偏差のノイズを加えた場合の累積リターンの変化が小さく、図 4 と同様にパラメータに付与したノイズに対して高い安定性を示している。これは株式市場にノイズが発生しても、予測結果が影響を受けにくいことを示して

おり、長期間にわたり安定した運用成績を継続できる要因と考えられる。Lasso 回帰は、必要のない説明変数を 0 とするためにスパース性が高く、これにより他の次元圧縮手法に比べてもノイズの影響を受けにくい構造となっていると考えられる。

Lasso 回帰は予測精度、安定性ともに高く、また Linear 回帰はともに低い。これを図 6 の結果と照らし合わせると、費用関数の形状が予測精度と安定性に影響を与えていることがわかる。Lasso 回帰では高次元の空間における運用モデルの類似度と累積リターンの大きさの間には依存関係があることがわかる。つまり、Lasso 回帰による株価予測モデルの費用関数は、単峰性のなだらかな形状をしていることがわかる。これは図 1(a)で示した安定したモデルの構造を反映したものであり、それゆえ株価予測の精度も高く、モデルの安定性も比較的高い結果となっていると言える。これに対して、Linear と Elastic, Ridge による手法では、凹凸が入り組んだような複雑なモデルが得られたことがわかる。つまり費用関数は各所に評価値が高い急峻な山があり、図 1(b)で示したような急峻で多峰性の評価関数になっている。このような費用関数を持つモデルは訓練データに対して過学習を起こしていると考えられ、それゆえ株価予測の精度が低く、モデルの安定性も低い結果になっていると言える。

このようにモデルのすべてのパラメータにノイズを付与し、t-SNE により 2 次元にマッピングすることにより、高次元モデルの費用関数を可視化できる。費用関数の形状がなだらかな単峰性である場合は、長期間にわたり運用成績が安定している株価予想モデルと評価することができる。また急峻な多峰性である場合は、安定性、運用成績ともに不確実な株価予想モデルと評価することができる。

6. おわりに

機械学習を用いて複雑なモデルを構築し株価予測を行う場合、オーバーフィッティングが要因となり、訓練時では高い予測精度を示す一方で、実際の運用では期待されていた予測精度が得られないことがある。オーバーフィッティングを起こしている株価予測モデルでは、評価関数が急峻な多峰性であると考えられ、一方で長期間にわたり安定した運用成績を継続している株価予測モデルでは、評価関数がなだらかな単峰性であると考えられる。

本研究では、まず複数の株価予測モデルにより長期間にわたる運用成績を比較し、それぞれのモデルについて評価関数を t-SNE を用いて可視化した。この結果、運用成績が最も高かった Lasso 回帰では、評価関数がなだらかな単峰性を示しており、運用成績が比較的低かった Ridge 回帰または Linear 回帰では評価関数が多峰性であった。このことから、t-SNE を用いて評価関数を可視化することは、株価予測モデルの安定性や汎用性を評価する指標になり得ることが示された。

本研究では評価関数の形状を目視により判断したが、関数の多峰性を検定する手法は存在する。評価関数の形状を多峰性の検定を用いて定量的に評価し、モデルの安定性と予測精度をより正確に示すことができる指標を作成することを、今後の研究の課題とする。

参考文献：

- [1] 松井和宏・佐藤晴夫「GA による株取引戦略獲得における近傍評価法の改良」『人工知能学会全国大会』第 24 回, 2010 年.
- [2] Pearson, K.: "On Lines and Planes of Closest Fit to Systems of Points in Space," *Philosophical Magazine*, Vol. 2, No. 11, pp. 559–572, (1901)
- [3] Torgerson, W. S.: "Multidimensional scaling: I. theory and method," *Psychometrika*, Vol. 17, No. 4, pp. 401–419, (1952)
- [4] Tenenbaum, J. B., De Silva, V., and Langford, J. C.: "A Global Geometric Framework for Nonlinear Dimensionality Reduction," *Science*, Vol. 290, No. 5500, pp. 2319–2323, (2000)
- [5] Roweis, S. T., and Saul, L. K.: "Nonlinear Dimensionality Reduction by Locally Linear Embedding," *Science*, Vol. 290, No. 5500, pp. 2323–2326, (2000)
- [6] Belkin, M., and Niyogi, P.: "Laplacian Eigenmaps and Spectral Techniques for Embedding and Clustering," In *NIPS*, Vol. 14, pp. 585–591, (2001)
- [7] Maaten, L. v. d., and Hinton, G.: "Visualizing Data using t-SNE," *Journal of Machine Learning Research*, Vol. 9 (Nov), pp. 2579–2605, (2008)
- [8] Roy, S. S., Mittal, D., Basu, A., and Abraham, A.: "Stock Market Forecasting Using LASSO Linear Regression Model," *Afro-European Conference for Industrial Advancement, Advances in Intelligent Systems and Computing*, Vol. 334, pp. 371–381, (2015)
- [9] 松本健・牧本直樹「LSTM による時系列予測と株式投資戦略への応用」『人工知能学会金融情報研究会』第 22 回, 2019 年.

t 過程ボラティリティ変動モデル Student's t -Process Volatility Model

濃野 歩^{1,2*} 内山 祐介² 中川 慧³
Ayumu Nono^{1,2} Yusuke Uchiyama² Kei Nakagawa³

¹ 東京大学大学院 工学系研究科

¹ The University of Tokyo, Graduate School of Engineering ² 株式会社 MAZIN

² MAZIN Inc.

³ 野村アセットマネジメント株式会社

³ Nomura Asset Management Co, Ltd.

Abstract: アセットアロケーションやデリバティブの計算において、金融資産の変動規模を表すボラティリティが活用されている。一方で、ボラティリティは直接観測される量ではないため、観測量に対する潜在変数を用いたモデル化が行われている。これらのモデルは総じてボラティリティ変動モデルとよばれており、主に計量ファイナンスや金融工学の分野において使用されてきた。従来のボラティリティ変動モデルのほとんどは線形モデルであるため、非線形性を有する複雑なボラティリティ変動を推定することができない。潜在変数の非線形ダイナミクスを推定する機械学習モデルとして、ガウス過程動的潜在変数モデルが提案されている。本研究では、ボラティリティの非線形ダイナミクスを外れ値に対してロバストの推定することを目的に、スチューデントの t 過程を動的潜在変数モデルに拡張したモデルを提案する。提案モデルの潜在変数とハイパーパラメータを粒子フィルタに基づいてオンライン推定する。これにより、観測された金融資産に対応するボラティリティ変動を推定する。

1 はじめに

アセットアロケーションやデリバティブの価格計算は金融工学や計量ファイナンスの主要な問題として学術界と実業界の双方において研究が行われてきた。これらの問題においては、金融資産の価格変動を直接対象とするのではなく価格変動のリターンの変動に基づいた方法論が構築されている。理想化された状況ではリターンの変動は正規分布に従うことが前提とされているが、実際に観測される金融資産価格のリターンの変動は正規分布よりも裾の厚い確率分布に従うことが知られている [1]。この観測事実を説明するために、ボラティリティという変動の大きさを表す量が利用されている。これにより、金融市場のボラティリティ変動を正確に捉えることが現代の金融工学や計量ファイナンスの主要な問題のうちの1つとして認識されるようになっていく。

一般に、ボラティリティはリターンが従う条件付き正規分布の分散として定義されている。金融工学や計量ファイナンスの分野では、ボラティリティを観測されない潜在変数として与え、ボラティリティの時間発展に

する種々の時系列モデルが提案されている。このような時系列モデルは総じてボラティリティ変動モデルと呼ばれている [2]。ボラティリティ変動モデルは観測変数であるリターンと潜在変数であるボラティリティとから成る動的ベイズモデルであるため、ベイズの定理に基づいて、予測・状態推定・平滑化の操作を実施することが可能である。

近年は、ボラティリティ変動モデルのような統計的時系列モデルのみならず、機械学習の手法を使用したボラティリティ推定法も提案されている [3]。ボラティリティ変動は直接観測することができない潜在変数であるため、潜在変数を取り入れた機械学習モデルが必要となる。このようなベイズ学習モデルとしてはガウス過程回帰モデルが存在し [4]、金融の諸問題に対してもいくつかの応用例が報告されている [5, 6]。また、金融資産価格のリターン変動のような非正規分布に従うデータに対してガウス過程回帰モデルを拡張したスチューデントの t 過程回帰モデルが提案されており [7]、金融時系列データの解析 [8] やアセットアロケーションの問題 [9] に対して適用されている。

本研究では、先行研究 [9] において提案されたスチューデントの t 過程潜在変数モデルに時系列構造を取り入れることを目的に動的潜在変数モデルへの拡張を行う。

*連絡先： 東京大学大学院 工学系研究科
〒 277-1131 千葉県柏市柏の葉 5-1-5
E-mail: nono-ayumu303@g.ecc.u-tokyo.ac.jp

t -過程潜在変数モデルにおいてはハイパーパラメータ同様に潜在変数も観測データから推定される必要があるため、学習に要する時間が増大してしまうことが懸念されていた。この問題に対して、本研究では動的潜在変数に加えてハイパーパラメータも潜在変数とみなすことで粒子フィルタによるオンライン学習法を提案する。提案手法の応用例として、提案手法による為替データのボラティリティ推定結果についても紹介する。

2 先行研究

2.1 ボラティリティ変動モデル

ボラティリティ変動モデルの中でも最も基本的でかつ使用されているものは以下に示す GARCH モデルである。

$$x_t \sim \mathcal{N}(0, \sigma_t^2), \quad (1)$$

$$\sigma_t^2 = \alpha_0 + \sum_{j=1}^q \alpha_j x_{t-j}^2 + \sum_{i=1}^p \beta_i \sigma_{t-i}^2 \quad (2)$$

ここで、 x_t は平均が 0 で分散 σ_t^2 の正規分布からサンプルされる確率変数であり、分散の時間発展は式 (2) によって与えられる。パラメータ α_j, β_i はそれぞれ正の値をとり、観測データが得られれば最尤推定によって求められる。 p と q はそれぞれ回帰の次数であり、式 (1) と (2) の組を GARCH(p, q) モデルと呼ぶ。この時系列モデルを基本として、非対称な効果を導入したり、多変量へと拡張することが目的に応じて行われている [10]。

2.2 ガウス過程回帰モデル

任意の有限個の $\{x_1, x_2, \dots, x_n\}$ と確率過程 $f(\cdot)$ に対して、 $\{f(x_1), f(x_2), \dots, f(x_n)\}$ の同時確率密度関数が正規分布で与えられるとき、 $f(\cdot)$ をガウス過程という。ガウス過程が従う確率密度関数は無限次元ベクトルが従う正規分布であるため、平均値関数 $m(\cdot)$ と共分散関数 $K(\cdot, \cdot)$ を

$$m(x) = \mathbb{E}[f(x)], \quad (3)$$

$$K(x, x') = \mathbb{E}[(f(x) - m(x))(f(x') - m(x')))] \quad (4)$$

で定義すると、 $X = [x_1, x_2, \dots, x_n]^T$ が与えられたときの確率密度関数は $p(f|X) = \mathcal{N}(m(X), K(X, X))$ となる。確率過程 f がガウス過程として抽出されることを明示する際には、 $f \sim \mathcal{GP}(m(\cdot), K(\cdot, \cdot))$ と表記する。簡単のため、ガウス過程の平均関数は 0 とされることが多い。共分散関数はカーネル関数 $k(\cdot, \cdot)$ により、

$$K(x, x') = k(x, x') \quad (5)$$

で与えられる。カーネル関数は非負の対称関数であるため、 $K(X, X)$ は正定値対称行列となる。カーネル関数としては動的基底関数 (Radial Basis Function; RDF)

$$k_{\text{RBF}}(x, x') = \alpha \exp(-l^{-2} \|x - x'\|^2) \quad (6)$$

が最もよく用いられている。動的基底関数はハイパーパラメータとして α と l を持つ。これらは最尤推定等の最適化法によって決定される。

観測データの組 $\mathcal{D} = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ に対して $X = [x_1, x_2, \dots, x_n]^T$, $Y = [y_1, y_2, \dots, y_n]^T$ とする。この (X, Y) を学習させたガウス過程から、未知のデータ $X^* = [x_1^*, x_2^*, \dots, x_m^*]^T$ に対する予測値 $Y^* = [y_1^*, y_2^*, \dots, y_m^*]^T$ は、平均関数 f^* と共分散関数 K^* がそれぞれ

$$f^* = m_X + K_{X^*, X} K_{X, X}^{-1} Y, \quad (7)$$

$$K^* = K_{X^*, X^*} - K_{X^*, X} K_{X, X}^{-1} K_{X, X^*} \quad (8)$$

で与えられる正規分布 $\mathcal{N}(f^*, K^*)$ から抽出される。

2.3 t -過程回帰モデル

ガウス過程では、確率過程 $f(\cdot)$ が従う確率密度関数として正規分布を仮定していた。そのため、金融時系列のように正規分布よりも裾の厚い確率分布に従うデータに適用する際には、正確な推定を行うことができなくなる。このようなデータに対してガウス過程を拡張したモデルが t -過程である [11]。 t -過程は、確率過程 $f(\cdot)$ が自由度 ν のスチューデントの t -分布

$$\begin{aligned} \mathcal{T}(m, K, \nu) &= \frac{\Gamma(\frac{\nu+n}{2})}{[(\nu-2)\pi]^{\frac{n}{2}} \Gamma(\frac{\nu}{2}) |K|^{\frac{1}{2}}} \\ &\times \left[1 + \frac{1}{\nu-2} (y-m)^T K^{-1} (y-m) \right]^{-\frac{\nu+n}{2}} \end{aligned} \quad (9)$$

に従うモデルである。ここで、 $m(\cdot)$ と $K(\cdot, \cdot)$ はそれぞれ平均関数と共分散関数であり、 $\Gamma(\cdot)$ はガンマ関数である。確率過程 $f(\cdot)$ が t -過程であるとき、 $f \sim \mathcal{TP}(m(\cdot), K(\cdot, \cdot); \nu)$ と表記する。ガウス過程同様に、 t -過程の平均関数も一般性を損なうことなく 0 として扱われることが多い。

t -過程の予測分布もまた t -分布となる。そのときの自由度、平均関数および共分散関数は以下のように更新される [8]。

$$\nu^* = \nu + n, \quad (10)$$

$$m^* = m + K_{X^*, X} K_{X, X}^{-1} Y \quad (11)$$

$$K^* = \frac{\nu - \beta - 2}{\nu - n - 2} \left[K_{X^*, X^*} - K_{X^*, X} K_{X, X}^{-1} K_{X, X^*} \right] \quad (12)$$

ガウス過程とは異なり、 t -過程ではデータ数の影響が自由度と共分散関数の更新式に反映されていることが確認できる。

2.4 t -過程潜在変数モデル

t -過程潜在変数モデルでは入力 X が潜在変数として与えられる。観測データ $y \in \mathbb{R}^D$ と潜在変数 $x \in \mathbb{R}^Q$ とが t -過程 $f \sim \mathcal{TP}(m(\cdot), K(\cdot, \cdot); \nu)$ によって $y = f(x)$ と関係づけられることを仮定し、 N 個の観測データを並べたものを $Y \in \mathbb{R}^{D \times N}$ 、 N 個の潜在変数を並べたものを $X \in \mathbb{R}^{Q \times N}$ としたときに

$$p(Y|X) = \frac{\Gamma\left(\frac{\nu+D}{2}\right)}{[(\nu-2)\pi]^{\frac{D}{2}} \Gamma\left(\frac{\nu}{2}\right) |K_{X,X}|^{\frac{1}{2}}} \times \left[1 + \frac{1}{\nu-2}(Y - m_X)^T K_{X,X}^{-1}(Y - m_X)\right]^{-\frac{\nu+D}{2}} \quad (13)$$

で与えられるモデルを、 t -過程潜在変数モデルと定義する。スチューデントの t 分布は $\nu \rightarrow \infty$ の極限で正規分布に収束するため、 t -過程潜在変数モデルはガウス過程潜在変数モデルを内包することがわかる。また、ガウス過程潜在変数モデル同様に、 t -過程潜在変数モデルにおいても一般性を損なうことなく平均関数を $m(\cdot) = 0$ とすることができる。

潜在変数とハイパーパラメータは観測データに対する最尤推定によって求められる。式 (13) に対応する対数尤度関数は

$$\begin{aligned} \log p(Y|X) &= \log \Gamma\left(\frac{\nu+D}{2}\right) - \frac{D}{2} \log[(\nu-2)\pi] \\ &\quad - \log \Gamma\left(\frac{\nu}{2}\right) - \frac{1}{2} \log |K_{X,X}| \\ &\quad - \frac{\nu+D}{2} \log \left(1 + \frac{1}{\nu-2} \Delta\right), \end{aligned} \quad (14)$$

$$\Delta = (Y - m_X)^T K_{X,X}^{-1}(Y - m_X) \quad (15)$$

で与えられる [9]。この対数尤度に対して (確率的) 勾配法、変分推論、マルコフ連鎖モンテカルロ法等を用いることで潜在変数とハイパーパラメータを推定することができる。

3 提案モデル

3.1 t -過程ボラティリティ変動モデル

ボラティリティ変動は直接観測することできないため、GARCH モデルに代表されるような動的潜在変数としてモデル化されている。GARCH モデルやその派生形の多くはボラティリティ変動を線形の時系列モデルで推定している [10]。ここでは、 t -過程潜在変数モデルを動的潜在変数に拡張することで、ボラティリティ変動の非線形ダイナミクスを推定する。また、 t -過程をベースとしたモデリングにより、ガウス過程をベースとした

モデルよりも、ロバストな推定が行えることが期待される。

時刻 t における金融資産価格を p_t としたとき、対数収益率は $x_t = \log(p_t/p_{t-1})$ で与えられる。このとき、 x_t に対応するボラティリティを σ_t とする。ここで、観測量 x_t と潜在変数 σ_t に対して、 t -過程ボラティリティ変動モデルを以下のように定義する。

$$x_t \sim \mathcal{T}(0, \sigma_t^2; \nu), \quad (16)$$

$$v_t := \log \sigma_t^2, \quad (17)$$

$$v_t = f(v_{t-1}, x_{t-1}; \nu) + \epsilon_t \quad (18)$$

$$\epsilon_t \sim \mathcal{N}(0, \sigma_n^2) \quad (19)$$

観測量 x_t は 0 を中心とし、パラメータが σ_t^2 で与えられる自由度 ν の t 分布に従うものとし、動的潜在変数 v_t は実数全体を値域としてとるように式 (17) によって定義する。動的潜在変数 v_t の時間発展は式 (18) によって与えられる。式 (18) の右辺における確率過程 f は t -過程として抽出され、以下のように与えられる。

$$f \sim \mathcal{TP}(m, k; \nu), \quad (20)$$

$$m(\xi_{t-1}) = av_{t-1} + bx_{t-1}, \quad (21)$$

$$k(\xi_{t-1}, \xi'_{t-1}) = \gamma \exp(-l^{-2} \|\xi_{t-1} - \xi'_{t-1}\|^2) \quad (22)$$

ただし、 $\xi_t = (x_t, v_t)$ である。また、ハイパーパラメータは $\theta = (\nu, \sigma_n, a, b, \gamma, l)$ である。観測データの系列 $\{x_{1:T}\}$ が与えられたときに、動的潜在変数の系列 $\{v_{1:T}\}$ とハイパーパラメータ θ を推定することで、ボラティリティ変動を求めることが可能となる。本研究では粒子フィルタを用いたオンライン推定手法を提案する。

3.2 粒子フィルタ

粒子フィルタは事前分布をランダムサンプリングによるモンテカルロ近似によって推定する方法であり、確率分布を多数の粒子によって表現する。そのため、非線形システムに対しても適用でき、システムノイズや観測ノイズを多峰性分布で表現することも可能である [12]。

粒子フィルタの基本的なアイデアは、事前分布と事後分布をこれらの条件付き分布に従う多数の粒子 (サンプル) を用いて近似するという点である。ここで、粒子数 N のサンプル集合を用いて分布を近似することを考える。 $\{v_{1:t-1}^i\}_{i=1}^N$ と W_{t-1}^i をそれぞれ、時刻 $t-1$ までの潜在変数とそれに付随する重みとする。重みは正規化されており、 $\sum_{i=1}^N W_{t-1}^i = 1$ である。これらを用いると時刻 $t-1$ での事後分布 $p(v_{1:t-1}|x_{1:t-1})$ は次のように近似される [13]。

$$\hat{p}(v_{1:t-1}|x_{1:t-1}) = \sum_{i=1}^N W_{t-1}^i \delta(v_{1:t-1}) \quad (23)$$

ただし、 $\delta(\cdot)$ はディラックのデルタ関数である。時刻 t での状態推定を行うに、粒子のリサンプリングを行う。リサンプリングは重み W_{t-1}^i に従って行われるため、重みが小さい粒子を選択的に次のステップに残し、重みの小さい粒子を消滅させる。こうして再び得られたサンプル集合 $\{v_{1:t-1}^j\}$ によって時刻 t での予測分布 $p(v_t|v_{1:t-1}, x_{1:t-1})$ が表現できる。各粒子の重みは観測量が与えられた時の各粒子の尤度に基づいて定められるため

$$\tilde{W}_t^i \propto p(x_t|v_t^i) \quad (24)$$

という関係をみだす。規格化条件を考慮することで、時刻 t における重みが

$$W_t^i = \frac{\tilde{W}_t^i}{\sum_{i=1}^N \tilde{W}_t^i} \quad (25)$$

によって求められる。以上が粒子フィルタの実施手順である。

3.3 オンライン推定アルゴリズム

粒子フィルタの実装において、ハイパーパラメータを定数として更新すると粒子の縮退が生じてしまい推定が上手く行かないことが指摘されている。そこで、本研究ではハイパーパラメータを動的潜在変数 θ_t として取り扱うことでオンライン推定を実施する。

動的潜在変数 v_t およびハイパーパラメータ θ_t のオンライン推定アルゴリズムを以下の手順で実施する。

1. 入力: オンライン推定に際し、予め次の2つの情報を与えておくものとする。

粒子数 N

初期分布 $p_0(v), p_0(\theta)$

2. 初期化: N 個2組の粒子群を抽出し、一方を動的潜在変数を表す粒子群とし、もう一方をハイパーパラメータを表す粒子群とする。それぞれの重みは一樣に与える。

$$\{v_0^i\}_{i=1,\dots,N} \sim p(v)$$

$$\{\theta_0^i\}_{i=1,\dots,N} \sim p(\theta)$$

$$W_{v,0}^i = 1/N$$

$$W_{\theta,0}^i = 1/N$$

3. 各パラメータ粒子の重みを算出: まず、 N 個の動的潜在変数の粒子 $\{v_{t-1}^i\}$ から時刻 $t-1$ における重み付き平均値を求める。

$$\bar{v}_{t-1}' = \sum_{i=1}^N W_{v,t-1}^i v_{t-1}^i \quad (26)$$

次に、ハイパーパラメータ θ_t と動的潜在変数 v_t 、および観測値 x_t で定められる確率過程 $f(v_t, x_t, \theta_t)$

をもとに、動的潜在変数の粒子を生成する。

$$v_t'^i = f(\bar{v}_{t-1}', x_{t-1}, \theta_{t-1}^i) \quad (27)$$

生成した N 個の推定値 $\{v_t'^i\}$ に対して尤度を求め、それを規格化して粒子の重みを算出する。

$$W_{\theta,t}^i \propto p(x_{t-1}|v_t'^i, \theta_{t-1}^i) \quad (28)$$

得られた重みに基づいて、 N 個のハイパーパラメータの粒子 $\{\theta_t^j\}_{j=1}^N$ を生成する。

4. 時刻 t における潜在変数の生成: N 個のハイパーパラメータの粒子 $\{\theta_{t-1}^i\}$ から時刻 $t-1$ におけるハイパーパラメータの重み付き平均値を求める。

$$\bar{\theta}_{t-1} = \sum_{i=1}^N W_{\theta,t-1}^i \theta_{t-1}^i \quad (29)$$

次に、確率過程 $f(v_{t-1}^i, x_{t-1}, \bar{\theta}_{t-1})$ から動的潜在変数の粒子を生成する。

$$v_t^i = f(v_{t-1}^i, x_{t-1}, \bar{\theta}_{t-1}) \quad (30)$$

5. 動的潜在変数の推定: 時刻 t における観測値 x_t が得られたときに、 N 個の動的潜在変数の粒子についての尤度を求める。この尤度を規格化することで、以下のように粒子の重みを算出する。

$$W_{v,t}^i \propto p(x_t|v_t^i, \bar{\theta}_{t-1}) \quad (31)$$

この重みから算出される重み付き平均値

$$\hat{v}_t = \sum_{i=1}^N W_{v,t}^i v_t^i \quad (32)$$

が動的潜在変数の推定値である。

6. フィルタ: 重みに基づいて、 N 個の動的潜在変数 $\{v_t^j\}_{j=1}^N$ を抽出する。

繰り返し $t := t+1$ として3に戻る。

4 実証分析

ここでは、代表的な為替指数を用いて t -過程ボラティリティ変動モデルによるボラティリティ変動の推定を行う。データセットとして、2010年の米ドル/日本円為替レートの2ヶ月分、469サンプル（3時間足）を使用した。対数収益率 x_t の統計量は以下の通りである。高い尖度と負の歪度という金融時系列特有の性質が確認され、正規性を満たさないことがわかる。

推定期間: 2ヶ月 (469 サンプル)




図 1: ボラティリティ変動の推定結果 (自由度 $\nu = 8$)




図 2: ハイパーパラメータの推定結果 (自由度 $\nu = 8$)

平均: 1.59×10^{-2}

分散: 1.32

歪度: -4.52

尖度: 5.44×10

観測量である対数収益率 x_t に対応するボラティリティ変動を推定した結果を図 1 に示し、それと同時にオンライン推定したハイパーパラメータの推定結果を図 2 に示す。図より、実施したオンライン推定においてハイパーパラメータが収束している様子を確認することができる。また、自由度を $\nu = 1 \sim 30$ の間で変化させたときの対数尤度を図 3 に示す。それぞれの自由度に対して 10 回の数値実験を行い、それらの平均値をプロットした。自由度と尤度との間には相関係数 -0.85 の負の相関があり、自由度が小さいときに尤度は大きくなる傾向にあるといえる。スチューデントの t 分布は $\nu \rightarrow \infty$ の極限で正規分布に収束することが知られており、実用上は $\nu \geq 30$ ではほぼ正規分布と同等であると見なせることから、自由度と尤度との間に負の相関が存することは、 t 過程ボラティリティ変動モデルはガウス過程ボラティリティ変動モデルよりも優位なモデルであることを意味する。また、同様の数値実験を 観測量の変動がより大きい 12 時間足で行うと、負の相関がより顕著に現れたため、 t 過程ボラティリティ変動モデルはガウス過程ボラティリティ変動モデルよりも外れ値に対するロバストな推定が可能であることが確認できる。

5 まとめ

本研究では、 t -過程動的潜在変数モデルを金融資産変動のボラティリティ推定に応用した、 t -過程ボラティリ




図 3: 自由度と尤度の関係

ティ変動モデルを提案した。動的潜在変数とハイパーパラメータの推定を行うために、粒子フィルタを応用したオンライン推定手法を開発した。提案モデルを米ドル/日本円の為替レートに適用することで、対応するボラティリティ変動を推定した。 t -過程ボラティリティ変動モデルの自由度と観測データに対する対数尤度との関係から、提案モデルは先行研究で提案されているガウス過程ボラティリティ変動モデルに対して優位に推定可能であることを確認した。

今後の課題として、 t -過程動的潜在変数モデルのロバスト性の定量的評価指標の作成や、変分推論を用いたハイパーパラメータ推定法の構築を検討している。

参考文献

- [1] Benoit B Mandelbrot. The variation of certain speculative prices. In *Fractals and scaling in finance*, pp. 371–418. Springer, 1997.

- [2] ボラティリティ変動モデル. シリーズ現代金融工学 / 木島正明監修. 朝倉書店, 2000.
- [3] Blanka Horvath, Aitor Muguruza, and Mehdi Tomas. Deep learning volatility, 2019.
- [4] C.E. Rasmussen and C.K.I. Williams. *Gaussian Processes for Machine Learning*. Adaptive computation and machine learning series. University Press Group Limited, 2006.
- [5] Joan Gonzalvez, Edmond Lezmi, Thierry Roncalli, and Jiali Xu. Financial applications of gaussian processes and bayesian optimization, 2019.
- [6] Rajbir S Nirwan and Nils Bertschinger. Applications of gaussian process latent variable models in finance. In *Advances in Intelligent Systems and Computing*, pp. 1209–1221, 2019.
- [7] Amar Shah, Andrew Wilson, and Zoubin Ghahramani. Student-t processes as alternatives to gaussian processes. In *Artificial intelligence and statistics*, pp. 877–885, 2014.
- [8] 中川慧, 角屋貴則, 内山祐介. 金融時系列のための深層 t 過程回帰モデル. 第 21 回 人工知能学会 金融情報学研究会 (SIG-FIN), 2018.
- [9] Yusuke Uchiyama and Kei Nakagawa. Tplvm: Portfolio construction by student’s t -process latent variable model. *Mathematics*, Vol. 8, No. 3, p. 449, 2020.
- [10] Timo Teräsvirta. An introduction to univariate garch models. In *Handbook of Financial time series*, pp. 17–42. Springer, 2009.
- [11] Amar Shah, Andrew Wilson, and Zoubin Ghahramani. Student-t processes as alternatives to gaussian processes. In *Artificial Intelligence and Statistics*, pp. 877–885, 2014.
- [12] Takekazu Kato. Introduction of particle filter and its implementation. *IPSJ SIG Technical Report*, Vol. 157, No. 22, p. 161, 2007.
- [13] Yue Wu, José Miguel Hernández-Lobato, and Zoubin Ghahramani. Gaussian process volatility model. In Z. Ghahramani, M. Welling, C. Cortes, N. D. Lawrence, and K. Q. Weinberger, editors, *Advances in Neural Information Processing Systems 27*, pp. 1044–1052. Curran Associates, Inc., 2014.

Adaptive Elastic Dynamic Mode Decomposition を用いた モメンタム戦略の改良

Improving Momentum Strategies using Adaptive Elastic Dynamic Mode Decomposition

内山 祐介^{1*} 中川 慧²
Yusuke Uchiyama¹ Kei Nakagawa²

¹ 株式会社 MAZIN

¹ MAZIN Inc.

² 野村アセットマネジメント株式会社

² Nomura Asset Management Co, Ltd.

Abstract: 動的モード分解 (DMD: Dynamic Mode Decomposition) は多変量時系列データのダイナミクスを安定・中立不安定多様体に対応した固有モードの重ね合わせによって表現する、流体解析の分野で提案された新しい手法である。動的モード分解は対象とする多変量時系列の支配方程式を陽に必要とせず、データのみから時空間ダイナミクスの構造を抽出する。また、DMD は時間および空間変数の次元削減手法であり、高次元の時空間ダイナミクスに埋め込まれた本質的に重要な低次元の時空間的特徴を抽出することが可能となる。この特徴を利用すると、多変量時系列の複雑な時間発展の中から単一方向のトレンド成分に対応するモードを抽出することができる。本研究では、スパースな時空間構造を抽出するため、DMD を拡張した Adaptive Elastic DMD(AEDMD) を提案し、これを用いて伝統的なモメンタム戦略の改良を行う。具体的には、価格系列に対して AEDMD を適用し、価格系列の背後にある時空間構造に基づいた価格トレンドの推定を行う。推定されたトレンドに基づいて売買を行うことで、単純な過去のトレンドに基づくモメンタム戦略を上回ることが可能であることを実証する。

1 はじめに

株や債権、為替といった金融資産の価格変動は市場における投資家の行動や、各国の経済動向、感染症の拡大や自然災害の発生といった大小様々な要因によって決定づけられる。これらの要因が変動する時間スケールが異なることから、金融資産の価格変動はマルチタイムスケール性を持つといえる。この性質は市場におけるトレンドとして捉えられ、それに基づいたモメンタム戦略をとる投資家も存在する。したがって、時系列が有するマルチタイムスケール性を推定することは投資戦略の観点からも有益であるといえる。

複雑系において頻繁に観測される非線形ダイナミクスは、一般に異なるスケールの時空間変動を示すことが知られている。こうした系の観測量を様々な運動モードに分解する方法として、クープマンモード分解法が提案された [1]。これは、クープマン作用素と呼ばれる非

線形力学系の観測量に対して定義された線形作用素の離散スペクトルに対応する固有モード系によって観測量を表現する方法である。対象とする系が非線形系であっても、クープマン作用素を導入することにより線形作用素に対する解析が行えるようになることがこの方法の利点である。クープマンモード分解法は、対象とする非線形ダイナミクスを記述する支配方程式に関する情報が得られていない状況であっても、観測データからダイナミクスを再構成することができる。したがって、金融資産価格変動のような時系列データは観測されるものの第一原理となる支配方程式が存在しない対象の解析に適しているといえる。

クープマンモード分解を具体的に実行する際にいくつかの方法が提案されているが、これらの中でも活発に研究されているものとして動的モード分解 (DMD: Dynamic Mode Decomposition) が知られている [2]。DMD は気象科学の分野を中心に使用されていた固有直交モード分解法を動的モードに拡張することでダイナミクスの解析が行えるようにした手法であり、特に流体力学の分野での応用が盛んに行われている。また、金

*連絡先: 株式会社 MAZIN
〒111-0035 東京都台東区西浅草 3 丁目 29-14
E-mail: uchiyama@mazin.tech

融の分野における応用もはじめられており [3, 4], DMD を使用した投資戦略や景気循環の推定に関する事例が報告されている [5].

多変量の時系列が与えられたとき, 現時刻の状態量を 1 期先の状態量に写す線形写像を特異値分解 (SVD) によって推定することで DMD は実行される. したがって, なにかしらの基準に従って分析者が設定した SVD の特異値行列の階数だけ動的モードが得られることになる. SVD の階数決定における分析者の恣意性を排除することを目的に, SVD の目的関数に L^1 正則化項を付与したスパース DMD が提案された [6]. これにより, 適切な動的モードの選択が可能となることが期待される.

スパース DMD は SVD の目的関数に L^1 正則化項を付与することで実現されるが, 線形回帰における正則化の理論においては L^1 正則化だけでは不十分であることが指摘されている. 具体的には, 対象とするデータから構成されるベクトルの中に比較的相関の強い成分の組が存在すると, それらのうちの 1 成分しか選択されない性質がある. また, 変数選択の際に一致性と漸近正規性とを合わせてオラクル性というが, L^1 正則化のみではオラクル性を満たさないことが指摘されている. 線形回帰におけるこれらの問題を解決する正則化法として, Adaptive Elastic Net という手法が提案されている [7].

本研究では, スパース DMD の階数決定における問題を解決することを目的に, Adaptive Elastic Net を DMD に適用した Adaptive Elastic Dynamic Mode Decomposition (AEDMD) を提案する. それと同時に, これを用いたモメンタム戦略を提案し, 従来のモメンタム戦略に対する優位性を株式先物指数を用いた実証分析によって提示する.

2 関連研究

2.1 クープマン作用素

観測量が常微分方程式や発展方程式の解として定義されるとき, 観測量の関数に対してクープマン作用素は定義される [8]. ここでは, 配位空間 \mathcal{M} 上の点 $\mathbf{x} \in \mathcal{M}$ と写像 $\mathbf{f}: \mathcal{M} \rightarrow \mathcal{M}$ に対して, 以下の常微分方程式が与えられているとする.

$$\frac{d\mathbf{x}}{dt} = \mathbf{f}(\mathbf{x}) \quad (1)$$

ここで観測量 \mathbf{x} は正の実数 t をパラメータに持つため, $\mathbf{x} = \mathbf{x}(t)$ である. また, 写像 \mathbf{f} は十分になめらかであるとする. このとき, 配位空間 \mathcal{M} 上で定義された関数 $g: \mathcal{M} \rightarrow \mathbb{R}$ 全体からなる空間に対して内積

$$\langle g_1, g_2 \rangle = \int g_1(\mathbf{x}) g_2(\mathbf{x}) d\mathbf{x} \quad (2)$$

を導入すると, この空間は L^2 ノルム

$$\|g\|_{L^2} = \left(\int g(\mathbf{x})^2 d\mathbf{x} \right)^{\frac{1}{2}} \quad (3)$$

によってヒルベルト空間となる. クープマン作用素 \mathcal{K} はこのヒルベルト空間の上に

$$\mathcal{K}g(\mathbf{x}) = g(\mathbf{f}(\mathbf{x})) \quad (4)$$

によって定義される線形作用素である. したがって, 有限次元の配位空間上の点の運動は式 (1) によって定められる非線形ダイナミクスであったとしても, クープマン作用素を導入することにより無限次元空間上の線形ダイナミクスとしてとらえることができるようになる.

クープマン作用素はヒルベルト空間の上で定義された線形作用素であるから, スペクトル分解が可能である. すなわち, 固有値問題

$$\mathcal{K}\varphi = \lambda\varphi \quad (5)$$

によって定められるスペクトルと固有関数によって展開することができる. ここでは簡単のため離散スペクトル $\{\lambda_n | n \in \mathbb{N}\}$ のみ存在したとすると,

$$\mathcal{K}g = \sum_n \lambda_n \varphi_n \quad (6)$$

によって展開される. これにより, 対象としているダイナミクスを固有関数 (モード) の特徴に基づいて捉えることができるようになる.

2.2 動的モード分解

実世界で観測されたデータに対してクープマン作用素の固有関数展開を適用する際には, データ空間の次元が有限であることから, なにかしらの近似を行う必要がある. このような近似手法の一つとして提案されたのが DMD である [2].

観測データの系列 $\{\mathbf{x}_t\}_{0 \leq t \leq T}$, $\mathbf{x}_t \in \mathbb{R}^N$ に対して観測行列

$$X_1 = \begin{pmatrix} | & | & \cdots & | \\ \mathbf{x}_0 & \mathbf{x}_1 & \cdots & \mathbf{x}_{T-1} \\ | & | & \cdots & | \end{pmatrix} \quad (7)$$

および

$$X_2 = \begin{pmatrix} | & | & \cdots & | \\ \mathbf{x}_1 & \mathbf{x}_2 & \cdots & \mathbf{x}_T \\ | & | & \cdots & | \end{pmatrix} \quad (8)$$

を導入する. ここで, これらの観測行列に対して

$$X_2 \approx A X_1 \quad (9)$$

を満たす行列 A が存在したとすると,

$$A = X_2 X_1^\dagger \quad (10)$$

が A の推定値として得られる. ここで, X_1^\dagger は観測行列 X_1 のムーア・ペンローズ逆行列である. 一般に観測行列は高次元であるため, 行列 A を直接求めることは計算上の困難を伴う. そこで, 観測行列 X_1 を

$$X_1 = U \Sigma V^* \quad (11)$$

と特異値分解すると

$$A = X_2 V \Sigma^{-1} U^* \quad (12)$$

が得られる. ここで, 行列 A の低ランク射影を

$$\tilde{A} = U^* A U \quad (13)$$

とし, 行列 Λ を対角行列とすると, 固有値問題

$$\tilde{A} W = W \Lambda \quad (14)$$

が導出される. ここで, W は行列 \tilde{A} の固有ベクトルからなる行列であり, 行列 Λ は固有値を成分として持つ対角行列である. これらを用いて得られる行列

$$\Phi = X_2 V \Sigma^{-1} W \quad (15)$$

の列ベクトル ϕ_k が行列 A の動的モードである. ここで, 行列 Λ の要素 λ_k と時系列データのサンプリング間隔 Δt から

$$\omega_k = \frac{\ln \lambda_k}{\Delta t} \quad (16)$$

を導出し, 初期値 x_0 と行列 Φ に対して

$$x_0 = \Phi b \quad (17)$$

をみたすベクトル b を求めると, 観測データが従うダイナミクスは

$$x_t = \sum_{k=1}^r \phi_k e^{\omega_k t} b_k \quad (18)$$

によって構成される. ここで, r は行列 Σ のランクである. 以上が, DMD の実施手順である. 式 (18) からわかるように, 行列 A の低ランク近似における r の値によって DMD の結果は異なる.

2.3 スパース DMD

DMD によって得られる動的モード数の選択において, 低ランク近似のランク数 r の決定は分析者に委ねられる. ランク数 r の決定を自動的に行うことを目的に, スパース DMD が開発された [6].

式 (18) と観測行列 X_1 の定義より, 対角行列

$$D_b = \text{diag}(b_1, b_2, \dots, b_r) \quad (19)$$

および, ヴァンデルモンド行列

$$V_{\text{and}} = \begin{pmatrix} 1 & \lambda_1 & \lambda_1^2 & \dots & \lambda_1^{T-1} \\ 1 & \lambda_2 & \lambda_2^2 & \dots & \lambda_2^{T-1} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & \lambda_r & \lambda_r^2 & \dots & \lambda_r^{T-1} \end{pmatrix} \quad (20)$$

に対して, DMD が観測データのダイナミクスを再構成できているときには

$$X_1 \approx \Phi D_b V_{\text{and}} \quad (21)$$

が有効に成り立っているといえる. そこで, $m \times n$ 行列 Z のフロベニウスノルム

$$\|Z\|_F = \sqrt{\sum_{i=1, j=1}^{m, n} |z_{i,j}|^2} \quad (22)$$

によって, 評価関数

$$J(b) = \|X_1 - \Phi D_b V_{\text{and}}\|_F \quad (23)$$

を導入すると, DMD はこの評価関数の最小値問題と等価であることがわかる.

この評価関数に対して L^1 正則化項

$$g_1(b) = \sum_{i=1}^r |b_i| \quad (24)$$

を付与し, 最小値問題

$$\arg \min_b J(b) + \gamma g_1(b) \quad (25)$$

を解くことで, ランク数 r も同時に決定することが可能となる. ここで, $\gamma > 0$ は正則化項の寄与度を表すパラメータである. 式 (25) を最小値問題の解として得られるモード展開をスパース DMD と呼ぶ.

3 Adaptive Elastic Dynamic Mode Decomposition

DMD ではダイナミクスの低ランク近似におけるランク数 r の決定に際して自由度が残されていたが, スパース DMD は L^1 正則化項付きの最小値問題を解くことによりランク数 r を自動的に決定することが可能となった. これは L^1 正則化の変数選択能力によるものである.

一方で, L^1 正則化には以下に示す問題点があることも指摘されている.

1. 観測データセット数を N , 観測データからなるベクトルの要素数を p としたときに, たかだか N 個までの変数が選択される.
2. 観測データからなるベクトルの各要素ごとに強い相関がある場合には, それらの中から 1 つだけ変数が選択される.
3. オラクル性, すなわち, 変数選択の一致性と選択された変数の漸近正規性が保証されていない.

これらの問題点を解決することを目的に, いくつかの正則化項付き線形回帰モデルが提案されている. 本研究では, 上記 3 つの問題点すべてを解決することを目的に解決された Adaptive Elastic Net [7] とよばれる手法を DMD に適用する.

まず, 以下の式で定義される L^2 正則化項

$$g_2(\mathbf{b}) = \sum_{i=1}^r |b_i|^2 \quad (26)$$

を式 (25) に追加した最小値問題

$$\arg \min_{\mathbf{b}} J(\mathbf{b}) + \gamma_1 g_1(\mathbf{b}) + \gamma_2 g_2(\mathbf{b}) \quad (27)$$

を考える. ここで, $\gamma_1, \gamma_2 > 0$ はそれぞれの正則化項の寄与度あわすパラメータである. この正則化項付き回帰問題は Elastic Net とよばれている. 式 (27) の解を \mathbf{b}_{ELS} としたときに, 重み係数 $\mathbf{w} \in \mathbb{R}^r$ を

$$w_i = \left(b_{\text{ELS},i} - \frac{1}{N} \right)^{-\eta} \quad (28)$$

によって定める. ここで, N は観測データセットで, η は正の実パラメータである. この重み係数を用いて,

$$g'_1(\mathbf{b}) = \sum_{i=1}^r w_i |b_i| \quad (29)$$

なる正則化項を導入すると, 正則化項付き最小値問題

$$\arg \min_{\mathbf{b}} J(\mathbf{b}) + \gamma'_1 g'_1(\mathbf{b}) + \gamma_2 g_2(\mathbf{b}) \quad (30)$$

が得られる. この最小値問題の解は, 先に挙げた L^1 正則化の問題点をすべて解決しているためスパース DMD の改良版と見ることが出来る. 式 (30) を解くことで得られるモード展開が本研究で提案する AEDMD である. ここでは, 単純なモメンタム戦略と AEDMD を用いた改良版モメンタムとのパフォーマンス比較を行う.

3.1 データセット

本研究では, 表 1 に示す 15 個の株式先物指数の日次データを用いた分析を行う. データの使用期間は 2000 年 5 月から 2020 年 4 月までの 20 年間とする.

3.2 分析手順

次の手順で AEDMD を用いたトレンド予測を行い, 各株式先物指数の投資ウェイト w_i を決定する.

- サンプル数分のデータを指数化¹する.
- 直近の価格 p_t と AEDMD の式 (30) から 20 日先の価格 \hat{p}_t を予測する.
- 予測した価格と直近の価格から騰落率 $\hat{r}_i = \hat{p}_t / p_t - 1$ を計算する.
- 騰落率のランクを用いて各資産のウェイトを $w_i = 1/20 \times (\text{rank}(\hat{r}_i) - N/2)$ と決める [9].

また比較手法として用いる単純なモメンタム戦略は, サンプル数分の過去のリターンの合計を予測リターンとして用いる.

時点 t におけるポートフォリオのリターンは

$$R_t = \sum_{j=1}^{15} r_{j,t} w_{j,t-1} \quad (31)$$

によって求められる. ここで $r_{j,t}$ は株式先物指数 j の時点 t におけるリターンであり, $w_{j,t-1}$ は株式先物指数 j の時点 t におけるウェイトを表す. ポートフォリオのリターンから計算される平均リターン (Mean), 標準偏差で表されるリスク (SD), リスク・リターン (SR) を用いてそれぞれのモメンタム戦略のパフォーマンスを評価する. 各指標の定義を以下に示す.

$$\text{Mean} = \frac{1}{T} \sum_{t=1}^T R_t \quad (32)$$

$$\text{SD} = \sqrt{\frac{1}{T-1} \sum_{t=1}^T (R_t - \text{Mean})^2} \quad (33)$$

$$\text{SR} = \text{Mean}/\text{SD} \quad (34)$$

3.3 分析結果

分析結果は表 2 の通りである. なお, 表中のサンプル数は上記分析手順で示したサンプル数を表す. サンプル数が 250 および 750 の場合を除くすべてのサンプル数で, AEDMD を用いたモメンタム戦略は単純なモメンタム戦略を大幅に上回っていることが確認できる. これは, それらの状況において AEDMD のトレンド予測能力が優れているからであると考えられる.

¹価格水準を調整するために最初の値を 1 とし, 以降はサンプル数分の騰落率を乗算する.

表 1: 取引対象の株式先物指数

Equity	S&P500 (SP)	NASDAQ (NQ)	CA (PT)	GB (Z)	FR (CF)	DE (GX)	EU (VG)	ES (IB)
future	NL	CH	NIKKEI	TOPIX	HK	AU	SG	
(15 assets)	(EO)	(SM)	(NK)	(TP)	(HI)	(XP)	(QZ)	

表 2: シミュレーション結果

DMD									
サンプル数	20	40	60	120	250	500	750	1000	1250
Mean	-0.002%	0.000%	0.001%	0.000%	0.003%	0.007%	0.006%	0.007%	0.009%
SD	0.064%	0.064%	0.062%	0.065%	0.063%	0.061%	0.058%	0.056%	0.055%
SR	-2.913%	0.285%	2.058%	0.683%	4.541%	11.682%	10.443%	12.942%	16.035%
Momentum									
サンプル数	20	40	60	120	250	500	750	1000	1250
Mean	-0.002%	0.000%	0.001%	0.000%	0.004%	0.005%	0.007%	0.006%	0.007%
SD	0.064%	0.064%	0.061%	0.065%	0.065%	0.066%	0.061%	0.060%	0.060%
SR	-3.065%	-0.472%	1.513%	0.317%	5.432%	8.061%	11.024%	10.840%	11.251%

4 まとめ

本研究では, DMD に Adaptive Elastic Net を応用することで多変量時系列データからスパースな時空間構造を抽出することが可能な AEDMD を提案した. 提案手法の有効性を検証することを目的に, AEDMD をモメンタム戦略に応用し, 従来手法とパフォーマンスを比較した. その結果, AEDMD は従来のモメンタム戦略と比較して金融市場のトレンド予測能力が高いことが確認された.

従来の DMD や本研究で提案した AEDMD は複雑な挙動を示す多変量時系列のダイナミクスを抽出する手法であるが, それらの実施手順から明らかなようにランダムな外乱を受けることを想定はしていない. 一方で, 一般に金融の諸問題に現れる時系列はランダムな外乱を受けることを前提としたモデル化が行われている. DMD の拡張モデルの中にはベイジアン DMD と呼ばれるランダムな外乱を受けている多変量時系列から動的モードを推定する手法が存在する. 本研究で提案した AEDMD をこの方向に拡張することで, ランダムな外乱に対するロバスト性を高めることが今後の課題である.

参考文献

- [1] Igor Mezić. Spectral properties of dynamical systems, model reduction and decompositions. *Non-linear Dynamics*, Vol. 41, No. 1-3, pp. 309–325, 2005.
- [2] Peter J Schmid. Dynamic mode decomposition of numerical and experimental data. *Journal of fluid mechanics*, Vol. 656, pp. 5–28, 2010.
- [3] Jordan Mann and J Nathan Kutz. Dynamic mode decomposition for financial trading strategies. *Quantitative Finance*, Vol. 16, No. 11, pp. 1643–1655, 2016.
- [4] Noemi Nava, Tiziana Di Matteo, and Tomaso Aste. Financial time series forecasting using empirical mode decomposition and support vector regression. *Risks*, Vol. 6, No. 1, p. 7, 2018.
- [5] Ling-xiao Cui and Wen Long. Trading strategy based on dynamic mode decomposition: Tested in chinese stock market. *Physica A: Statistical Mechanics and its Applications*, Vol. 461, pp. 498–508, 2016.
- [6] Mihailo R Jovanović, Peter J Schmid, and Joseph W Nichols. Sparsity-promoting dynamic mode decomposition. *Physics of Fluids*, Vol. 26, No. 2, p. 024103, 2014.
- [7] Hui Zou and Hao Helen Zhang. On the adaptive elastic-net with a diverging number of parameters. *Annals of statistics*, Vol. 37, No. 4, p. 1733, 2009.

- [8] BO Koopman and J v Neumann. Dynamical systems of continuous spectra. *Proceedings of the National Academy of Sciences of the United States of America*, Vol. 18, No. 3, p. 255, 1932.
- [9] Ralph SJ Koijen, Tobias J Moskowitz, Lasse Heje Pedersen, and Evert B Vrugt. Carry. *Journal of Financial Economics*, Vol. 127, No. 2, pp. 197–225, 2018.

人工知能は相場操縦という不正な取引を勝手に行うか？ — 遺伝的アルゴリズムが人工市場シミュレーションで学習する場合 —

Does an artificial intelligence perform market manipulation with its own discretion?
— A genetic algorithm learns in an artificial market simulation —

水田孝信 *1
Takanobu Mizuta

*1 スパークス・アセット・マネジメント株式会社
SPARX Asset Management Co., Ltd.

人工知能が相場操縦を行った場合の責任の所在が議論されている。そこで本研究では、遺伝的アルゴリズムを用いた人工知能が人工市場シミュレーションを用いて学習するモデルを構築し、人工知能の作成者が相場操縦という取引戦略を全く意図していなかったにも関わらず、人工知能が学習を通じて相場操縦という取引戦略を発見するのかが調べた。その結果、人工知能は相場操縦に他ならない取引を最適な取引として見つけ出した。この結果は、株式取引を行う人工知能の作成者には、人工知能が相場操縦を行わないようにする義務を負わせるなどの規制の必要性を示唆している。

1. はじめに

人工知能が事故を起こしたり不正行為を行った場合の責任の所在はどうあるべきか、多くの分野で議論されている。株式市場においては、人工知能が相場操縦を行った場合の責任の所在が議論されている。相場操縦とは市場価格などの相場を自分に有利になるように動かし利益を得ようとする取引戦略であり、本来の価格形成を阻害する不正な行為であるとして多くの市場で禁止されている *1*2。

日本では、日本銀行金融研究所が設置した“アルゴリズム・AIの利用を巡る法律問題研究会”が、“投資判断におけるアルゴリズム・AIの利用と法的責任”という報告書を公表している [アル 18] *3。この報告書によると、株式取引を行う人工知能の作成者が相場操縦をする意図をもって人工知能を作成し、実際に人工知能が相場操縦を行った場合は作成者に責任があるとしている。一方で、作成者が相場操縦をする意図が全くなかったにも関わらず、人工知能が勝手に相場操縦を行った場合、責任が問えないケースがある」と指摘している *4。このことは、実際に相場操縦が行われているにも関わらず誰も責任が問われない場合があることを示しており、市場の質の維持を妨げる問題である。

この報告書では、“人工知能が自分の取引が市場価格に与える影響を継続的に学習・分析して、作成者が知らないところで相場操縦という取引戦略を発見し、実行することも考えられる”，という重要な指摘をしている。多くの場合、人工知能が学習中の取引戦略を評価するときは、実データを用いて“もし取引していたらどうなっていたか”を分析する、いわゆるバックテストという手法をとる。しかしながらバックテストでは、

自身の取引が市場価格に与える影響を考慮できないため、この報告書が指摘するような、“自分の取引が市場価格に与える影響を継続的に学習・分析する”ことはできない。そのため、人工知能がバックテストで学習している限りは、人工知能が勝手に相場操縦をする心配はない。そういうこともあり、この報告書が懸念しているようなことが本当に人工知能にできるのかどうかは調べられていない。

一方で、コンピュータ上に仮想的に市場を作り出し分析する人工市場（金融市場のエージェントベースモデル）を用いたシミュレーション [水田 19b, 高安 20, Mizuta 19c] *5 であれば“自分の取引が市場価格に与える影響を継続的に学習・分析する”ことが可能である。

そこで本研究では図 1 のように、遺伝的アルゴリズム *6 を用いた人工知能が人工市場シミュレーションを用いて学習するモデルを構築し、人工知能の作成者が相場操縦という取引戦略を全く意図していなかったにも関わらず、人工知能が学習を通じて相場操縦という取引戦略を発見し、実行に移すのか調べる。

2. モデル

人工知能を用いた取引を行う場合、人工知能はどのような取引戦略が利益を獲得するか学習し戦略の構築を行う。本研究では、人工知能の作成者が相場操縦という取引戦略を全く意図していなかったにも関わらず *7、人工知能が学習を通じて相

連絡先: mizutata@gmail.com

<https://mizutatakanobu.com>

当日の発表スライドは以下にある。

<https://mizutatakanobu.com/2020SIGFIN.pdf>

*1 相場操縦の詳しい定義は、<https://www.jpx.co.jp/regulation/preventing/manipulation/>

*2 日本においても証券取引等監視委員会が相場操縦などの不正取引の検挙事例を多くあげている。

<https://www.fsa.go.jp/sesc/jirei/index.htm>

*3 解説記事として [水田 20]

*4 人工知能の作成者がどのような者かによる。証券会社や資産運用会社、高速取引業者など規制対象の者は何かしら責任を問えるが、金融機関でない法人や個人の場合は、責任を問うのが難しいとされる。分かりやすい解説として [水田 19a] がある。

*5 人工市場シミュレーションはバブルや金融危機の発生メカニズムの解明に貢献したことはもちろん、現実の金融市場の規制や制度、ルールの変更の議論に貢献し始めている [水田 19b, 高安 20, Mizuta 19c]。

*6 遺伝的アルゴリズムとは生物の進化から着想を得た最適解を近似的に求める計算手法であり、入力値を遺伝子に見立て適応度（出力値）が高い遺伝子が生き残っていくことによって、最大の適応度（出力値）を持つ遺伝子（入力値）を探す手法である。優れた解説書として [Goldberg 89] がある。

*7 実際には作成者がいかなる投資戦略も意図せずに人工知能を作ることには難しい。しかし本研究では、いかなる投資戦略も意図しないことが明確なモデルであることが重要であるため、あえて売買戦略のモデル化を行わず、ある人工市場環境で最適なすべての取引を直接探し出すモデルとした。売買戦略がモデル化されていないため、学習していない環境での売買を出力できず、アウトサンプルでの検証はできない。しかし、本研究の目的はあくまでも相場操縦という戦略を人工知能が学習時点で見つけ出せるかどうか注目しており、実際にモデルを稼働させることは目的としないため、アウトサン

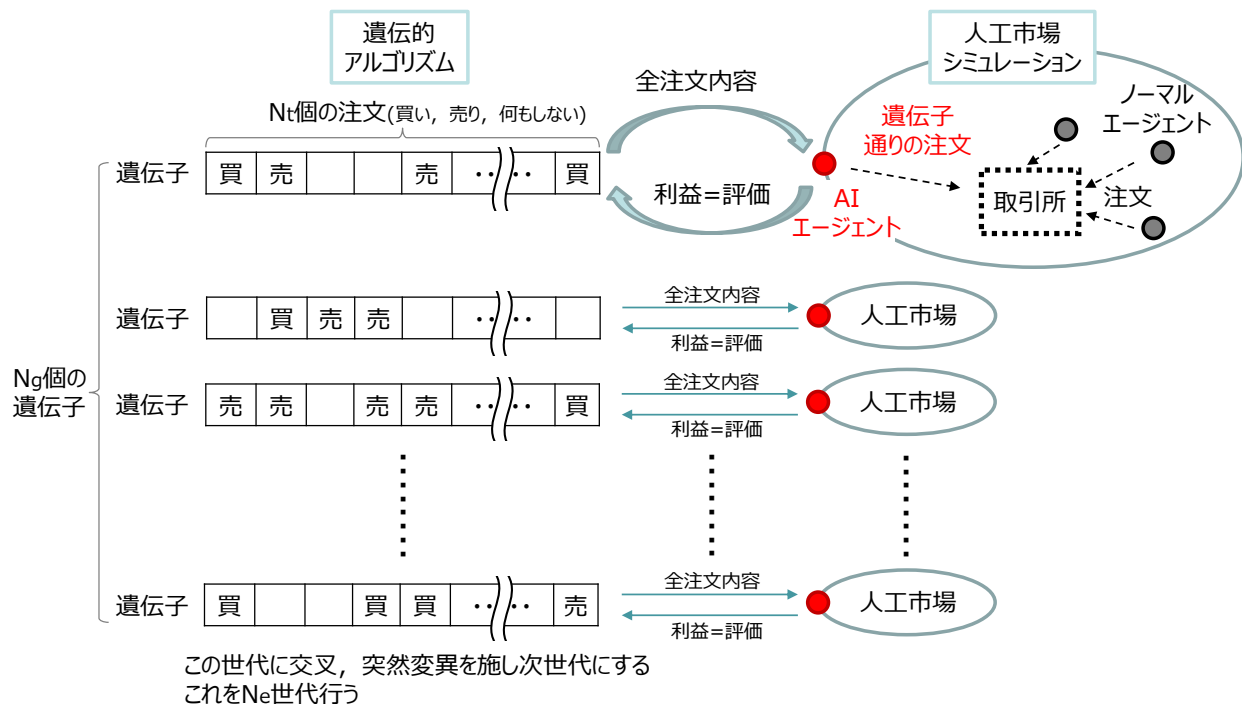


図 1: モデルの概要

場操縦という取引戦略を発見し、実行に移すのみに注目する。

図 1 は、本研究のモデルの概要である。作成者がいかなる投資戦略も意図しない人工知能として、すべての取引行動を 1 つの遺伝子とした遺伝的アルゴリズムを用いる。各遺伝子は人工市場を用いたシミュレーションで評価を行う。人工市場内には遺伝子通りの取引を行う AI エージェントを投入する。そして、この AI エージェントの利益をこの遺伝子の評価とし、遺伝的アルゴリズムによって高い評価の遺伝子を探し出す。この探し出す行為が人工知能の学習に相当する。

なお、各人工市場のノーマルエージェントのパラメータセットは、各時刻ごとに変化する乱数も含め、すべて同じものを用いる。そのため、仮に AI エージェントの売買が同じであれば、ノーマルエージェントの売買も同じとなる。

また、人工市場内での AI エージェントの取引は市場価格に影響を与えるが、比較のため、市場価格に影響を与えない場合 (バックテスト) も分析する。

以下ではまず、各遺伝子の評価を行う人工市場シミュレーションについて説明し、その後、優れた遺伝子を探す遺伝的アルゴリズムの説明を行う。

2.1 人工市場シミュレーション

本研究の人工市場モデルは [水田 19b, Mizuta 19c] のモデルを用いる。

本モデルでは 1 つの株式を取引対象とする。価格決定メカニズムは、ザラバ方式 (continuous double auction) *8 とし、独立して価格の決定・売買が行われる。注文できる価格の変化幅の最小単位 (呼値の刻み) は δP とし、注文価格のそれより小さい端数は、買い注文の場合は切り捨て、売り注文の場合は

切り上げる。

n 体のノーマルエージェントと、1 体の AI エージェントが存在する。各エージェントは保有する株数に制限はなく (キャッシュが無限大)、マイナスの保有数量 (空売り) にも制限はない。また、時刻は 1 体のエージェントが注文を出すたびに 1 増える、いわゆるティック時刻とする。

2.1.1 ノーマルエージェント

n 体のノーマルエージェントが売買に参加する。エージェント番号 $j = 1$ から順番に $j = 2, 3, 4, \dots$ と注文を出す。 $j = n$ が注文を出すと、次のティック時刻にはまた $j = 1$ から注文を出し繰り返される。注文数量は常に 1 株と一定とする。

注文価格 $P_{o,j}^t$ 、売り買いの別を以下のように決める。ティック時刻 t にエージェント j が予想する株価の変化率 (予想リターン) $r_{e,j}^t$ は、

$$r_{e,j}^t = (w_{1,j} \log \frac{P_f}{P_{t-1}^t} + w_{2,j} \log \frac{P^{t-1}}{P_{t-\tau_j-1}^t} + w_{3,j} \epsilon_j^t) / \sum_i w_{i,j} \quad (1)$$

とする。ここで、 $w_{i,j}$ はエージェント j の i 項目の重みであり、シミュレーション開始時に、それぞれ 0 から $w_{i,max}$ まで一様乱数で決める。 \log は自然対数である。 P_f は時間によらず一定のファンダメンタル価格、 P^t はティック時刻 t のすでに出されている注文のうち最も高い買い注文価格と最も安い売り注文価格の平均 (仲値)、 ϵ_j^t はティック時刻 t 、エージェント j の乱数項であり、平均 0、標準偏差 σ_ϵ の正規分布乱数である。 τ_j はシミュレーション開始時に 1 から τ_{max} までの一様乱数でエージェントごとに決める *9。

式 (1) の第 1 項目はファンダメンタル価格と比較して安ければプラスの予想リターンを高ければマイナスの予想リターンを示す、ファンダメンタル価値を参照して投資判断を行うファ

ルでの検証は不要と考える。

*8 ザラバ方式は、売り手と買い手の双方が価格を提示し、売り手と買い手の提示価格が合致するとその価格で直ちに取引が成立する方式である。

*9 ただし、 $t < \tau_j$ のときは、式 (1) の第 2 項目を 0 とした。

ンダメンタル投資家の成分である。第2項目は過去の価格推移から投資判断を行うテクニカル投資家の成分であり、過去のリターンがプラス(マイナス)ならプラス(マイナス)の予想リターンを示す。第3項目はノイズを示す。

予想リターン $r_{e,j}^t$ より予想価格 $P_{e,j}^t$ は、 $P_{e,j}^t = P_{o,j}^{t-1} \exp(r_{e,j}^t)$ で求まる。注文価格 $P_{o,j}^t$ は $P_{e,j}^t - P_d$ から $P_{e,j}^t + P_d$ の一様乱数で決める。ここで、 P_d は定数である。そして、売り買いの別は予想価格 $P_{e,j}^t$ と注文価格 $P_{o,j}^t$ の大小関係で決める。すなわち、

$$\begin{aligned} P_{e,j}^t > P_{o,j}^t &\text{なら1株の買い} \\ P_{e,j}^t < P_{o,j}^t &\text{なら1株の売り} \end{aligned} \quad (2)$$

とする^{*10}。注文を行ってからキャンセル時間 t_c だけ経過した注文はキャンセルする。

2.1.2 AI エージェント

AI エージェントはティック時刻 δt ごとに、1株の買い(注文価格はすでにある最も高い売り価格)または売り(注文価格はすでにある最も安い買い価格)、または何もしないの3通りのいずれかを行う^{*11}。1試行のシミュレーションはティック時刻 t_e まで行うため、AI エージェントは $N_t = (t_e - t_c)/\delta t$ 回行動を選ぶことになる。この行動は次節に述べる遺伝的アルゴリズムによって与えられる。

2.2 遺伝的アルゴリズム

2.2.1 遺伝子情報と人工市場

作成者がいかなる投資戦略も意図しない人工知能として遺伝的アルゴリズムを用いる。図1も参照。 N_g 個の遺伝子を用意する。1つの遺伝子は N_t 個の遺伝子情報を持つ。遺伝子情報は1つの注文に相当し、買い、売り、何もしないの3つどれか1つである。各遺伝子は前節で述べた人工市場シミュレーションを用いて、1体のAIエージェントに遺伝子情報である N_t 個の注文をティック時刻 δt ごとに順番に行わせ利益を算出する。遺伝子の評価はこの利益で行う。最後まで持っていた株式の価格は P_f と評価する。各遺伝子が用いる人工市場内のノーマルエージェントの行動は乱数も含め同じである。そのため、もしAIエージェントの行動が同じであれば、まったく同じ利益が得られる。

2.2.2 世代交代

全遺伝子 N_g 個のうち、利益が高かった上位 N_{ge} 個の遺伝子はそのまま残す。

残り $N_g - N_{ge}$ 個の各遺伝子は確率 R_c で、利益が高かった上位 N_{ge} 個の遺伝子からランダムに選んだ2つの遺伝子 g_0, g_1 を交叉させたものに置き換える。交叉はまず遺伝情報をすべて遺伝子 g_0 のものに置き換え、ランダムで決められた i_0 個目から i_1 個目の遺伝情報をすべて遺伝子 g_1 のものに置き換える。その後、その $N_g - N_{ge}$ 個の各遺伝子の各遺伝子情報に対して確率 R_m で買い、売り、何もしないをそれぞれ1/3の確率でランダムに書き換える突然変異が行われる。

このようにして次の世代を作成し、これを N_e 世代繰り返す。

なお、初めの世代は、すべての遺伝子のすべての遺伝子情報は買い、売り、何もしないをそれぞれ1/3の確率でランダムに決める。

*10 ただし、 $t < t_c$ のときは十分な板の厚さを確保するため、 $P_f > P_{o,j}^{t-1}$ なら1株の買い、 $P_f < P_{o,j}^{t-1}$ なら1株の売りとする。また、 $P^{t-1} = P_f$ とする。

*11 ただし、初めのティック時刻 t_c までは注文を出さない。シミュレーションを不安定にしないため、初めの t_c までは*10でも述べたように、十分な板の厚さを確保するための期間である。




図2: AI エージェントありの場合となしの場合の市場価格(仲値)の時系列




図3: AI エージェントありの場合の市場価格と200ティック時間ごとに集計したAIエージェントの売買数量(買いがプラス、売りがマイナス)

3. シミュレーション結果

人工市場に関するパラメータは、 $n = 900, w_{1,max} = 1, w_{2,max} = 100, w_{3,max} = 1, \tau_{max} = 1000, \sigma_\epsilon = 0.03, P_d = 1000, t_c = 2000, \delta P = 0.01, P_f = 10000, \delta t = 10$ とした。またシミュレーションは時刻 $t = t_e = 10000$ まで行った。遺伝的アルゴリズムに関するパラメータは、 $N_t = (t_e - t_c)/\delta t = 800, N_g = 10000, N_{ge} = 400, R_c = 0.65, R_m = 0.2, N_e = 1500$ とした。そのため、 $N_g \times N_e = 1.5 \times 10^7$ 回(1千5百万回)という膨大な回数の人工市場シミュレーションを行ったことになる。そして以下では、遺伝的アルゴリズムの最終世代で最も利益が高かった遺伝子情報(全注文内容)を用いる。

3.1 最初の試行の結果

図2は、AI エージェントがいる場合(AI エージェントあり)と、AI エージェントがいない場合(AI エージェントなし)の市場価格(仲値)の時系列である。AI エージェントによって、市場価格が変動が大きくなっていることがわかる。

図3は、AI エージェントありの場合の市場価格と200ティック時間ごとに集計したAIエージェントの売買数量(買いがプ

表 1: さらに 10 試行を行った結果

シミュレーション					
試行	$P_{min}/P_f - 1$	$P_{max}/P_f - 1$	$(P_{max} - P_{min})/P_f$	AI エージェントの売買数量	結果タイプ
2	-0.59%	4.12%	4.7%	518	相場操縦 (買い上げ)
3	-0.63%	4.49%	5.1%	506	相場操縦 (買い上げ)
4	-0.77%	5.37%	6.1%	496	相場操縦 (買い上げ)
5	-4.33%	0.00%	4.3%	414	相場操縦 (空売り下げ)
6	-0.14%	0.00%	0.1%	0	売買せず
7	-3.67%	0.03%	3.7%	489	相場操縦 (空売り下げ)
8	-0.77%	5.02%	5.8%	511	相場操縦 (買い上げ)
9	-0.61%	4.96%	5.6%	507	相場操縦 (買い上げ)
10	-3.68%	-0.01%	3.7%	491	相場操縦 (空売り下げ)
11	0.00%	0.17%	0.2%	0	売買せず

バックテスト					
試行	$P_{min}/P_f - 1$	$P_{max}/P_f - 1$	$(P_{max} - P_{min})/P_f$	AI エージェントの売買数量	結果タイプ
2	-0.04%	0.13%	0.2%	221	ファンダメンタル戦略
3	-0.08%	0.21%	0.3%	230	ファンダメンタル戦略
4	-0.10%	-0.03%	0.1%	0	売買せず
5	-0.10%	0.01%	0.1%	0	売買せず
6	-0.14%	0.00%	0.1%	413	ファンダメンタル戦略
7	-0.05%	-0.01%	0.0%	0	売買せず
8	-0.05%	0.23%	0.3%	482	ファンダメンタル戦略
9	-0.04%	0.11%	0.2%	529	ファンダメンタル戦略
10	-0.01%	0.13%	0.1%	567	ファンダメンタル戦略
11	0.00%	0.17%	0.2%	484	ファンダメンタル戦略




図 4: AI エージェントの売買が市場価格に影響を与えないバックテストの場合

ラス, 売りがマイナス) である。2000 ティック時刻あたりでは AI エージェントが大量に買うことで市場価格を上昇させている。3000 ティック時刻あたりでは買いの量を減らしているにもかかわらず市場価格は上昇を続けている。市場価格はファンダメンタル価格を上回っており、ノーマルエージェントのファンダメンタル戦略 (式 (1) の第 1 項) は下落を予想している。しかし、2000 ティック時刻あたりで AI エージェントの大量の買いで作られた大きな上昇により、ノーマルエージェントのテクニカル戦略 (式 (1) の第 2 項) は大きな上昇を予想すること




図 5: 試行 5

になってしまい、ファンダメンタル戦略の下落予想を上回ってしまう。そのため、AI エージェントが買いの量を減らしても、市場価格は上昇を続けている。その後、4000 ティック時刻から 6000 ティック時刻くらいまで AI エージェントは売っているが、3000 ティック時刻付近の上昇のおかげで、2000 ティック時刻付近で買った値段よりも高く売ることができている。

AI エージェントのこれらの取引行為は相場操縦に他ならない。

図 4 は、AI エージェントの売買が市場価格に影響を与えないバックテストの場合の市場価格と AI エージェントの売買数

量である(図2および図3とは価格を示す左縦軸のケールが違
うことに注意). AI エージェントの売買が市場価格に影響を
与えないため, 市場価格の推移は図2の AI エージェントがい
ない場合と全く同じとなる. AI エージェントは, 市場価格がフ
ァンダメンタル価格を下回っているほど多く買う傾向にあり, 通
常のファンダメンタル戦略をとっている. つまり, バックテス
トの場合, 相場操縦という取引手法は発見しない.

このことは, 人工知能が人工市場シミュレーションを使って
自分の取引が市場価格に与える影響を多く学習できる場合に
は相場操縦という取引戦略を発見できるが, 実データを用いた
バックテストでは相場操縦という取引戦略を発見できない可
能性を示唆している.

3.2 さらに 10 試行を行った結果

これまで行ったシミュレーションは, 各人工市場に共通に与
えたノーマルエージェントのパラメータセット, 1 つに対して
行われたものであった. そういう意味ではこれまでに行ったシ
ミュレーションが 1 試行と言える. ここでは, さらに 10 個の
パラメータセットを用いて 10 試行を行った結果を見る.

表 1 は, その 10 試行の結果の概要である. P_{min} , P_{max}
はそれぞれ, 市場価格の最小値, 最大値である. “結果タイプ”
の列では, “売買せず” は AI エージェントが全く売買しな
かった場合を, “相場操縦(買い上げ)” は, AI エージェントが市
場価格を上昇させるために大きな買いを行った場合を, “相場
操縦(空売り下げ)” は, AI エージェントが市場価格を下落さ
せるために大きな売りを行った場合を, “ファンダメンタル戦略”
は, AI エージェントが, 市場価格がファンダメンタル価格よ
り安いときに買い, 高いときに売る傾向があった場合を, それ
ぞれ示している.

相場操縦の場合は, $P_{max}/P_f - 1$ または $P_{min}/P_f - 1$ が示す
ように, 市場価格が大きく上昇するか大きく下落しており, AI
エージェントの売買が市場価格に大きな影響を与えているこ
とを示しています. ファンダメンタル戦略の場合は, AI エー
ジェントの売買数量が少なくないにも関わらず, $(P_{max} - P_{min})/P_f$
は小さく, 市場価格に大きな影響を及ぼしていないことが分
かる.

表 1 では, AI エージェントの売買が市場価格に影響を与
えるシミュレーションの場合と, 影響を与えないバックテストの
場合の結果も示している. シミュレーションの場合, 8 試行で
相場操縦となり, 残り 2 試行で売買せずとなった. これらの結
果は, 人工知能が最適な戦略として相場操縦を発見するのは簡
単であることを示唆している. バックテストの場合は, 相場
操縦の場合はひとつもなかった. このことは, 自分の売買が市
場価格に影響を与える考慮できないバックテストでは, 人工知
能は相場操縦という戦略を発見できない可能性を示唆している.

図 5 は, 試行 5 について, 図 3 と同じように, 市場価格と
200 ティック時間ごとに集計した AI エージェントの売買数量
(買いがプラス, 売りがマイナス) を示した. 試行 5 において
は, AI エージェントは多くの売りを行い市場価格に影響を与
え, 大きく下落させた. このことは, 人工知能は図 3 のよう
な買い上がりの相場操縦だけでなく, 図 5 のような空売り下
げの相場操縦も発見しうることを示唆している.

4. まとめと今後の課題

本研究では図 1 のように, 遺伝的アルゴリズムを用いた人
工知能が人工市場シミュレーションを用いて学習するモデルを
構築し, 人工知能の作成者が相場操縦という取引戦略を全く意
図していなかったにも関わらず, 人工知能が学習を通じて相場

操縦という取引戦略を発見するのか調べた.

その結果, 人工知能は相場操縦に他ならない取引を最適な
取引として見つけ出した. これは, 人工知能が人工市場シミュ
レーションを使って自分の取引が市場価格に与える影響を多く
学習できる場合には, 人工知能の作成者が全く意図していなく
ても, 相場操縦という取引戦略を発見できる可能性を示してい
る. ただし, 実データを用いたバックテストでは相場操縦とい
う取引戦略を発見できない可能性も示唆した.

これらの結果は, 株式取引を行う人工知能の作成者には, 人
工知能が相場操縦を行わないようにする義務を負わせるなどの
規制の必要性を示唆している.

本研究では図 1 全体でいえば 11 試行しか行っていない. 本
研究の目的は, 人工知能が学習を通じて相場操縦という取引戦
略を発見する可能性があるかどうかを調べることであるので,
1 試行で相場操縦が行われれば十分目的を達している. 法規制
を考える上では, 少なからず可能性があるかどうか重要であ
るからだ. しかし, それをどれくらい発見しやすいのかを調べ
ることも重要であろう. そのためには, もっと多くの試行が必
要である. それには高速な計算機が必要であり, 今後の課題で
ある.

付録

モデル構築の基本理念

人工市場シミュレーションを用いれば, まだ導入したことが
ない手数料体系を調べたり, その変更の純粋な効果やメカニ
ズムを議論したりできる. これが人工市場シミュレーション研究
の強みである. そして, 多くの人工市場シミュレーション研究
がこれまでにない環境が与える影響や, 規制やルールの変更
を分析してきた [水田 19b, 高安 20, Mizuta 19c].

ただその効果は確実な予想ではない. さまざまなケースで
のシミュレーションを行い, これまで予想されていなかった,
“あり得る” メカニズムでの現象を見つけておくことが, 人工
市場シミュレーションの大きな役割となる. 金融市場でこれか
ら実際におこる現象を定量的にも忠実に再現することが目的で
はなく, 環境の変化が, どのようなメカニズムで価格形成に影
響を与え, どのようなことが起こり得るのかという知識獲得が
目的である. これは例えば実証分析など他の手法ではできない
ことである.

人工市場モデルは普遍的に存在するマクロ現象を再現すべ
きであると考えられる. 人工市場シミュレーションでは, マクロ
現象である市場価格のリターンや売買数量をモデル化しない.
あくまで, 投資家を模した“エージェント”と取引所を模した
“価格決定メカニズム”といったミクロメカニズムをモデル化
し, そのミクロメカニズムの相互作用の積み上げとしてマクロ
現象が出力される. そのため, ミクロメカニズムのモデル化は
現実の市場に即したものとし, 結果として出力されるマクロ現
象は, 現実の市場で普遍的に存在するマクロ的性質を再現され
るように作らなければならない.

しかし, 普遍的ではなく特定の時期や資産, 地域で出現する
マクロ的性質すべてを再現することは本研究の目的ではない.
必要以上に多くのマクロ的性質を一つのモデルで再現しようと
すると, 過剰に複雑なモデルをもたらす, 関連する要素が多
くなりすぎて, 発生メカニズムの理解を妨げてしまう.

実際, 複雑な人工市場モデルに対して, モデルが複雑にな
るとパラメータが増えモデルの評価が困難になるという批判が
ある [Chen 12]. モデルが複雑すぎると関連する要素が多
くなりすぎて, 発生メカニズムの理解を妨げてしまう. また, パラ

表 2: AI エージェントがいない場合の各種統計量

リターン標準偏差	0.0103%
リターン尖度	1.54
ラグ	
1	0.081
二乗リターンの自己相関係数	0.041
2	0.032
3	0.047
4	0.018
5	

メータが増えるほどさまざまな出力がだせるようになり、モデルを作った人が導きたい結果へ恣意的に導くためのパラメータ設定が行われる恐れがある。シンプルでパラメータが少ないモデルほど、パラメータ調整によって特定の結果に導くことが困難であるため評価が容易となる。

以上により、本研究では、分析目的を果たせる範囲内なるべくシンプルなモデルの構築を行っている。実際の市場を完全に再現することを目的としておらず、普遍的ではなく特定の時期や資産、地域で出現するマクロ的性質すべてを再現することや、実際には存在するであろう投資家をすべて網羅することはあてて行っていない。

[Weisberg 12] が述べているように、よいシミュレーションモデルとはその研究目的によって異なる。そのため、本研究のモデルは本研究の目的にのみおいてよいモデルであり、他の研究目的においてはよいモデルではない。また [Weisberg 12] が述べているように、数理モデルと異なり、シミュレーションモデルは投資家などのミクロの行動やその行動の理由と、市場価格などのマクロ現象との相互作用のメカニズムの解明ができることが強みである。例えば、ノーベル経済学賞を受賞したシェリングはシミュレーションモデルを用いて人種隔離のメカニズムを議論したが、そのモデルではメカニズムの解明に焦点を当てたためどこにも存在しないシンプルな町を簡潔にモデル化していて、実際に存在する町の隔離状況の説明や予測はできないモデルであった [Schelling 06]。本研究でも、数理モデルが強みとするマクロ現象の特徴分析や予測といったことは目的とせず、メカニズムの解明に焦点をあてている。

モデルの妥当性

人工市場モデルの妥当性は実証分析で得られている fat-tail や volatility-clustering といった代表的な stylized fact が再現できるかどうかで評価される [LeBaron 06, Chen 12, 水田 14]。ファット・テールは、市場価格のリターンの分布が正規分布ではなく裾が厚い、すなわち、尖度が正であることである。ボラティリティ・クラスタリングは市場価格のリターンの 2 乗が、大きなラグでも自己相関係数が有意に正であることである。

[Sewell 11] など多くの研究で述べられているように、金融市場は不安定であり、安定的に、どのような時期にも有意に観測されるスタイライズド・ファクトはファット・テールとボラティリティ・クラスタリングの 2 つしかない。

しかも、これらは統計量の有意に正であることだけが安定して観測され、値そのものは、時期によって異なる。ファット・テールについては、実証分析でよく観測されるリターンの分布の尖度は 1 ~ 100 程度であり、ボラティリティ・クラスタリングについては、実証分析でよく観測されるリターンの自己相関は 0 ~ 0.2 程度と、かなりばらつきがある [Sewell 11]。

本研究のように、金融市場に共通する性質を分析対象とする

人工市場が再現すべきは、これらの統計量が有意に正であり、問題ない範囲に値が収まっていることであって、特定の値に近づけることは本質的ではない。

表 2 は、AI エージェントがいない場合の毎期のリターン $\log(P^t/P^{t-1})$ の標準偏差と尖度、リターンの 2 乗の自己相関である。リターンの尖度がプラスで、ファット・テールが再現されている。また、リターンの 2 乗の自己相関もプラスで、ボラティリティ・クラスタリングが再現されていると考えられる。

留意事項

本論文はスパークス・アセット・マネジメント株式会社の公式見解を表すものではありません。すべては個人的見解であります。

参考文献

- [アル 18] アルゴリズム・AI の利用をめぐる法律問題研究会：投資判断におけるアルゴリズム・AI の利用と法的責任，日本銀行 金融研究所 (2018)，
https://www.boj.or.jp/announcements/release_2018/re1180911a.htm/
- [Chen 12] Chen, S.-H., Chang, C.-L., and Du, Y.-R.: Agent-based economic models and econometrics, *Knowledge Engineering Review*, Vol. 27, No. 2, pp. 187–219 (2012),
<http://dx.doi.org/10.1017/S0269888912000136>
- [Goldberg 89] Goldberg, D. E.: *Genetic Algorithms in Search, Optimization, and Machine Learning*, Addison-Wesley Professional (1989)
- [LeBaron 06] LeBaron, B.: Agent-based computational finance, *Handbook of computational economics*, Vol. 2, pp. 1187–1233 (2006),
[http://dx.doi.org/10.1016/S1574-0021\(05\)02024-1](http://dx.doi.org/10.1016/S1574-0021(05)02024-1)
- [水田 14] 水田 孝信：人工市場シミュレーションを用いた金融市場の規制・制度の分析，博士論文，東京大学大学院工学系研究科 (2014)，
<http://hdl.handle.net/2261/59875>
- [水田 19a] 水田 孝信：高頻度取引（3 回シリーズ第 3 回）：高頻度取引ではないアルゴリズム取引と不正取引の取り締まり高度化，スパークス・アセット・マネジメント (2019)，
<https://www.sparx.co.jp/report/special/2764.html>
- [水田 19b] 水田 孝信：人工市場シミュレーションを用いた金融市場の規制やルール議論，証券アナリストジャーナル，Vol. 57, No. 5 (2019)，
https://www.saa.or.jp/learning/journal/each_title/2019/05.html
- [Mizuta 19c] Mizuta, T.: An agent-based model for designing a financial market that works well, *arXiv* (2019)，
<https://arxiv.org/abs/1906.06000>
- [水田 20] 水田 孝信：人工知能が不正取引を行ったら誰の責任か？，スパークス・アセット・マネジメント (2020)，
<https://www.sparx.co.jp/report/special/3071.html>

- [Schelling 06] Schelling, T. C.: *Micromotives and Macrobehavior*, W. W. Norton & Company (2006), (邦訳: 村井章子: ミクロ動機とマクロ行動, 勁草書房 (2016))
<http://www.keisoshobo.co.jp/book/b251669.html>
- [Sewell 11] Sewell, M.: Characterization of financial time series, *Research Note, University College London, Department of Computer Science*, No. RN/11/01 (2011),
<http://finance.martinsewell.com/stylized-facts/>
- [高安 20] 高安美佐子, 和泉潔, 山田健太, 水田孝信: マルチエージェントによる金融市場のシミュレーション, コロナ社 (2020),
<https://www.coronasha.co.jp/np/isbn/9784339028225/>
- [Weisberg 12] Weisberg, M.: *Simulation and Similarity: Using Models to Understand the World*, Oxford Studies in the Philosophy of Science (2012), (邦訳: 松王政浩: 科学とモデル-シミュレーションの哲学 入門-, 名古屋大学出版会 (2017))
<http://www.unp.or.jp/ISBN/ISBN978-4-8158-0872-3.html>

多変量時系列データを用いた分散型強化学習による 低リスク行動の学習

Modeling Low-risk Actions from Multivariate Time Series Data using Distributional Reinforcement Learning

佐藤 葉介^{1*} 張 建偉²
Yosuke Sato¹ Jianwei Zhang²

¹ 岩手大学大学院総合科学研究科

¹ Graduate School of Arts and Science, Iwate University

² 岩手大学理工学部

² Faculty of Science and Engineering, Iwate University

Abstract: In recent years, investment strategies in financial markets using deep learning have attracted a significant amount of research attention. The objective of these studies is to obtain investment behavior that is low risk and increases profit. Although Distributional Reinforcement Learning (DRL) expands the action-value function to a discrete distribution in reinforcement learning which can control risk, DRL has not yet been used to learn investment action. In this study, we construct a low-risk investment trading model using DRL. This model is back-tested on Nikkei 225 data and compared with Deep Q Network (DQN). We evaluate the performance in terms of final asset amount, standard deviation, and the Sharpe ratio. The experimental results show that the proposed method can learn low-risk actions with the increasing profit, outperforming the compared method DQN.

1 はじめに

近年、深層学習を用いた金融市場に関する研究が盛んに行われている [1, 2]. 金融市場は景気や為替などの経済的要因や政局などの経済外的要因など複雑な要因が関わり変動するため、確実な将来の状態予測や取引戦略の組み立てが困難な金融市場における投資行動の学習に関する研究はこれまでに多数されてきた [3, 4, 5, 6]. 特に近年は高い特徴表現力を持つ深層モデルを用いて取引エージェントを製作する研究がされている [7, 8, 9]. 多くの研究では利潤を増加させつつ保有する資産価値が減少するリスクへの対処をするという 2 つの課題に対して様々な手法が提案されてきた [10, 11, 12, 13]. ほとんどの深層強化学習を用いた先行研究では Deep Q Network (DQN) が提案手法のベースや比較手法として用いられている. これらの研究で用いられる評価値は、利潤の増大を測るためにテスト期間に得られた資産の多さ、その標準偏差をどれだけ安定して利益を得られるかを調べるために利用し、これら 2 つの評価値を統

合した、取ったリスクに対してリターンの大きさを示すシャープレシオ [14] が主に用いられている.

一方、分散型強化学習 [15] は深層強化学習における行動価値関数の各行動の評価値を値の分布に拡張した手法であり、ベンチマークにおいて DQN, Double DQN (DDQN), Dueling Network より優れた結果を残している. 分散型強化学習による行動価値関数では、ある行動で得られる報酬の期待値だけでなく定義した報酬の値の範囲で、各報酬が得られる期待値を離散分布で学習することができる. モデルの出力を人が観察しリスク操作をすることが可能な利点があり、行動価値関数の出力と手動で設定した歪度の要素積を計算することで、ある程度学習の対象ごとの性質に合わせた行動の選択をする改善手法も提案されている [16].

本研究では先に述べた金融市場の不確実性から起こる資産価値低下のリスクに対して、筆者の知るところで金融分野で応用されていない分散型強化学習を適用することで、低リスクな行動を獲得することを目的とする. 日経 225 を構成する銘柄に対してバックテストを行い、DQN と比較してシャープレシオや得られた利益などについて評価を実施した. 実験によりテスト環境の最終的な資産額についての標準偏差が、分散型強

*連絡先: 岩手大学大学院総合科学研究科
〒020-0066 岩手県盛岡市上田 4 丁目 3-5
E-mail: g0319083@iwate-u.ac.jp

化学習の方が小さく現れたことから日経 225 については DQN より小さなリスクの投資行動を学習できた結果が得られた。

2 関連研究

ポートフォリオマネジメントは利益の最大化やリスクの最小化を目的とした金融資産の分配をする問題であり、強化学習による適切な投資行動の学習が試みられている。価値ベースの手法として Shin[10] らは DQN を用いて 8 種類の暗号通貨と USD のポートフォリオマネジメントを学習させ、最も資産価値の減少を抑えた行動を学習できているため低リスクだとしている。方策ベースの手法として Xiong[11] らは Deep Deterministic Policy Gradient (DDPG) を用いて株価、保有株数、残高の状態からそれぞれの株に対する売却、保持、購入の行動を学習している。約 10 年分の Dow Jones 30 stocks についてバックテストを行い比較手法より利益とシャープレシオについて優位な結果を残した。また、Ye[13] らも DDPG を用いており、ニュース記事と株価の推移を前処理したデータからポートフォリオの割り当てを学習している。ベンチマークにおいては比較手法より優位な利益を出し、シャープレシオも概ね優位な結果を残した。CNN ベースの DDPG を構築し 12 種類の暗号通貨のポートフォリオマネジメントを行った研究もある[17]。Jiang[18] らは暗号通貨のポートフォリオマネジメントを行う EIIE フレームワークを開発し UBAH などの比較手法より portfolio value やシャープレシオについて優位な結果を得ている。EIIE フレームワークは方策ベースの手法であり、資産の潜在的な成長性から直近の予測を行う IIE のアンサンブル学習である。金融市場に関する研究では投資行動の学習に限らずリスクを考慮した手法が提案されているが、関連研究や過去の研究では分散型強化学習を用いた手法は取り入れられていない。本研究は分散型強化学習を投資行動の学習に初めて応用する。

3 手法

3.1 問題設定

本研究では金融市場における投資行動をマルコフ決定過程 $M(S, A, R, P)$ とする。 $s \in S$ は状態空間、 $a \in A$ は行動空間を表す。投資行動の対象資産は東京証券取引所第一部に上場している企業の株式と無リスク資産とし、所持している株式とともに状態 s に含まれる。また、行動 a は保持している無リスク資産で株式を購入、保持している株式の売却、資産の売買を行わない保持の 3 つを取りうる。

$R: S \times A \times S \rightarrow \mathbf{R}$ は報酬関数を表している。本手法では初期状態あるいは株式の購入時から売却時までの資産額の増減を報酬値に利用している。売却したときのみ即時報酬を与えるとそれまでの過程が評価されないため、報酬が得られたときに初期状態あるいは株式の購入を行ったときから売却したときまでの各状態 s に対して遅延報酬を与える。このとき、過去の状態に遡るにつれて割引率を適用することで偏りが現れる可能性を排除する。さらに各報酬値に対して DQN と同様に reward clipping を適用する。

遷移関数 $P: S \times A \times S \rightarrow [0, 1]$ は状態 s のとき行動 a を取り状態 s' へ遷移する状態遷移確率を表す。方策 $\pi(a | s)$ は状態 s の時の行動 a をとる確率を表す関数である。行動価値関数 $Q^\pi(s, a)$ は状態 s のとき方策 π に従い行動 a を取ったときに得られる期待報酬値を定義する。

$$Q^\pi(s, a) = \mathbf{E}[R(s, a)] + \gamma \mathbf{E}_{P, s}[Q^\pi(s', a')]$$

最適方策 π^* を学習し最適行動価値関数 $\mathbf{E}[Q^*(s, a)]$ の戻り値を最大化するような行動を学習することが目的となる。最適方策とは任意の初期状態 $s \in S$ から期待報酬を最大化することである。最適方策の学習にはいくつか手法が存在するが、Q 学習では以下の更新式により最適行動価値関数を学習する。

$$Q_\theta(s, a) \leftarrow \mathbf{E}[R(s, a)] + \gamma \mathbf{E}_P[\max_{a'} Q_\theta(s', a')]$$

DQN では Q_θ を CNN で表現しており様々な派生や応用 [9] がなされている。

3.2 分散型強化学習

森村 [19] らは期待リターンの再帰式であるベルマン期待方程式のリターンを分布に拡張した分布ベルマン方程式を定義している。分布ベルマン方程式を解くことでリターン分布を推定できるが分布ベルマン方程式は汎関数の自由度を持つため一般に推定は困難であるため近似が必要となる。

Bellemare[15] はリターン分布を多項分布で近似した categorical DQN を提案している。リターン分布は直感的には複数個の bin と呼ばれる 1 つの報酬値が得られる期待値を表すものが連続している。ハイパーパラメータとして設定した数だけの bin 数でリターン分布が構成される。近似リターン分布の bin 数 $M \geq 2$ と、近似リターン分布の上限 Q_{max} と下限 Q_{min} をハイパーパラメータとして定め、bin 間隔 Δ_z を

$$\Delta_z := \frac{Q_{max} - Q_{min}}{M - 1}$$

のように定数として定め、各 bin に対するリターン代表値を $Z_m, m \in \{1, \dots, |m|\}$

$$Z_m := Q_{min} + (m - 1)\Delta_z$$

とする。状態 s と行動 a の入力に対するリターン分布を表現する M 次元ベクトル $(q_1(s, a), \dots, q_M(s, a))$ を出力する深層モデル $\mathcal{S} \times \mathcal{A} \rightarrow \mathbf{R}^M$ を用いて、推定リターン分布 \hat{P} を

$$\hat{P}(C = z_m | s, a) := \frac{\exp(q_m(s, a))}{\sum_{m'=1}^M \exp(q_{m'}(s, a))},$$

$$\forall m \in \{1, \dots, M\}$$

として求める。このとき categorical DQN の行動価値の推定値 \hat{Q} は

$$\hat{Q}(s, a) \triangleq \sum_{m=1}^M z_m \hat{P}(C = z_m | s, a)$$

となる。 \hat{Q} は DQN と同様に近似分布ベルマン行動最適作用素 \hat{D} [15] を適用して現在の推定リターン分布 \hat{P} から目的分布 \hat{P}_n^{target} を求める。experience replay により得た経験 n を用いて目的分布 \hat{P}_n^{target} と現在の推定分布 $\hat{P}(\cdot | s_n, a_n)$ との差異が小さくなるように深層モデルの重みを更新する。

学習は DQN と同様に experience replay を取り入れる [20]。学習において 1 ステップ更新されるごとに、replay memory に現在の状態、次の状態、評価値を保存する。 n ステップに一度、ハイパーパラメータとして指定したバッチサイズだけ replay memory からデータを取り出し Target-Network の重みを学習する。

4 実験

categorical DQN による分散型強化学習を用いて、バックテストにより金融市場における投資行動を学習する実験を行った。DQN と比較して最終的な資産額、標準偏差、シャープレシオについて評価した。

4.1 データセットと前処理の手法

データセットは東京証券取引所第一部に上場しており、日経 225 に含まれる 225 銘柄を利用した。期間は 2010 年 1 月 4 日から 2019 年 12 月 30 日までの 10 年間の日足データを利用し、10 年分のデータが存在しない銘柄については、データが存在する年から 2019 年 12 月 30 日まで利用する。そのうちより過去の 9 割のデータを学習に用いて、より新しいデータを評価に用いる。市場は過去の状態の影響を受けて将来の状態が決定し

ていると考えられるため、評価において未来の情報を学習していないモデルを用いるようにする。

日足には始値 (open price)、高値 (high price)、低値 (low price)、終値 (close price) の 4 つの変数が含まれ、それぞれの変数について前処理を行う。本手法では前日からの値動き、すなわち差分を学習させる。さらに DQN と同様に複数ステップの情報をまとめて 1 つの状態とする。あるステップ t における n 日分の時系列データを用いた場合に replay memory に保存するデータは以下のようになる。

$$v_t^{diff} = v_t - v_{t-1}$$

$$\mathbf{v}_t = (f(v_t^{open\ diff}), f(v_t^{high\ diff}), f(v_t^{low\ diff}), f(v_t^{close\ diff}))$$

$$\mathbf{s}_t = (\mathbf{v}_t, \mathbf{v}_{t-1}, \dots, \mathbf{v}_{t-n+1})$$

v_t^{diff} はステップ t における前ステップとの差分の情報を含むベクトルを表す。 \mathbf{s}_t はステップ t における環境から観測される状態とする。 f は引数として得た値に対して正規化を行う関数とする。

次状態 \mathbf{s}_{t+1} はステップ $t+1$ において同様に計算したものである。 r_t は 3.1 節で述べたように報酬が得られてから与えられるため、それまで $\{\mathbf{s}_t, a_t, r_t, \mathbf{s}_{t+1}\}$ の組をスタックする。報酬が得られてからスタックしたデータに割引率を適用した報酬を与え、replay memory に保存される。

4.2 日経 225 データのバックテストによる投資実験

実験環境は Open AI Gym をもとに構築した。モデルや分散型強化学習 (DRL) に利用するパラメータは固定し、225 銘柄それぞれについて環境を構築し投資行動の学習を行った。初期状態として投資エージェントは無リスク資産である ¥1,000,000 を所有する。環境から観測される状態は日足であり、4.1 節のように前処理を行い replay memory に保存する。学習データを用いて 1 epoch だけ replay memory を構築してから学習を開始し、設定した頻度で experience replay による学習を行う。次に評価用の replay memory を用いて評価用の未知の期間について投資行動を行い、リセットした初期資産から増減した資産額を求める。評価期間が終了したときにエージェントが株式を保持している場合は無リスク資産と株式の時価額の和を最終的な資産額とする。モデルの初期状態や方策が ϵ -greedy 法でありランダムな要素を含むため 100 回実験を行い、資産額の平均、標準偏差、シャープレシオを計算する。シャープレシオ [14] は評価期間の間に増加した資産額の平均をその標準偏差で割った値とした。実験では無リスク資産の利子率は 0 とする。

表 1: 225 銘柄のテスト結果の平均値

	DQN	DRL(ours)
Asset Amount(YEN)	1,037,772	1,038,152
Standard Deviation(YEN)	106,287	100,938
Sharpe Ratio	0.229	0.239

表 2: 225 銘柄のテスト結果の標準偏差

	DQN	DRL(ours)
Asset Amount(YEN)	119,477	114,539
Standard Deviation(YEN)	83,549	89,181
Sharpe Ratio	0.702	0.733

DRL と DQN の共通パラメータとして、予備実験により、モデルは 5 層全結合とし隠れ層数 32, Q 学習の割引率を 0.9, replay frequency を 4, Adam- ϵ を 1.5×10^{-4} , 1 状態に含める日数を 8 日とした。DRL のパラメータは、モデルの最終層の bin 数を 31, Vmax を 10, Vmin を -10 とした。

評価値である最終的な資産額、標準偏差、シャープレシオについて期待値としての 225 銘柄の平均値を表 1 に、標準偏差を表 2 に示す。

表 1 より DRL は DQN に比べて 225 銘柄の平均の資産額、標準偏差、シャープレシオについて優位な結果となった。表 2 より 225 銘柄の各評価値の標準偏差は資産額のみ提案手法の方が優位な結果となっており、標準偏差やシャープレシオのばらつきは大きいことを示している。225 銘柄のうち最終的な資産額について DRL が優位であった銘柄の割合は 41.3%, 標準偏差は 63.1%, シャープレシオは 53.3% の銘柄について優位な結果となった。シャープレシオの平均値については提案法は DQN の 1.04 倍のシャープレシオとなっており、DQN に比べて比較的低リスクであり大きな資産を得られるといえる [14]。

5 考察

本実験では日経 225 に採用されているそれぞれの銘柄について学習し投資実験の評価を行った。この章では結果について考察する。

5.1 実験結果のヒストグラム

225 銘柄の結果について、最終的な資産のヒストグラムを図 1 に示す。いずれも縦軸は度数を表し、横軸については図 1 は各銘柄について最終的に得られた資産額の平均値、図 2 は最終的に得られた資産額の標準偏差、図 3 はシャープレシオを表している。図 1 が示




図 1: 最終資産額のヒストグラム比較




図 2: 最終資産額の標準偏差のヒストグラム比較

すように DRL と DQN が得られる最終的な資産額は目視だとほとんど差が無い。図 2 により、DQN に対して DRL は比較的多くの銘柄で標準偏差が小さいことから、比較的稳定した取引行動を学習できているといえる。

5.2 有意性の検証

本研究では最終的な資産額、標準偏差、シャープレシオについて 225 銘柄それぞれの結果について平均と分散を計算しているが、結果の有意性について調べる。DRL により得られた結果と DQN により得られた結果を 2 つの群として代表値の有意性を検定する。

まず、DRL と DQN の結果についてシャピロ-ウィルク検定により標本に正規性があることを帰無仮説としてテストした。DRL による結果の p 値は 5.49×10^{-10} , DQN による結果の p 値は 8.85×10^{-12} となり有意水準を 0.01 とすると帰無仮説が棄却され 2 つの結果は正規性を持たないことがわかった。

DRL と DQN の結果には同じ銘柄について投資行動を学習しているためデータ間の対応があり、正規性が




図 3: シャープレシオのヒストグラム比較

表 3: ウィルコクソンの符号付き順位検定結果

evaluation items	p value
Asset Amount	0.992
Standard Deviation	1.200×10^{-06}
Sharpe Ratio	0.470

無いことから、ノンパラメトリック検定であるウィルコクソンの符号付き順位検定により 2 群の標本の代表値に差がないことを帰無仮説としてテストした。各評価項目に対する検定の結果を表 3 に示す。

有意水準を 0.01 とすると標準偏差については帰無仮説が棄却され 2 群の代表値には有意差があると言える。しかし最終的な資産額とシャープレシオについては統計的には有意差があるとは言えない結果となった。

5.3 epoch 数の妥当性

多くの実験では複数の epoch 数にわたって学習するが本実験では 1 epoch のみ学習している。予備実験としてランダムに抽出した銘柄コード 5301 について 10,000 epoch まで学習を行い、1 epoch ごとに評価を行った結果を図 4 に示す。損失関数の最適化手法は Adam を用いており、学習率は 6.25×10^{-5} と低めにしても、epoch 数の増加に従って評価における最終的な資産額は振動しており明確な増加はしなかった。

図 5 に 10,000 epoch まで学習したときのモデルが出力した Q 値の平均値と標準偏差の推移を表す。評価段階においてモデルが 1 step ごとに出力した Q 値を 10,000 epoch ほど累積したものについて、各 step で平均値と標準偏差を計算している。epoch 数が多くなるにつれて明らかな Q 値の増加は無く振動が続き、Q 値が蓄積されるにつれて標準偏差が大きくなっている。Q 値が増加し資産額が増加していれば報酬設計が間違っていることになるが、Q 値の明確な増加傾向が現れな




図 4: 分散型強化学習を用いた 1 epoch ごとの評価




図 5: 分散型強化学習を用いた累計 Step ごとの Q 値

いことから epoch 数の増加に従い投資行動を改善するような学習がなされていないことがわかる。そのため 1 epoch のみの学習で評価を実施した。

6 結論

分散型強化学習により日経 225 を構成する銘柄からなる金融市場において投資行動の学習を行い、DQN と比較し最終的な資産額、標準偏差、シャープレシオの平均値について優位な結果を得た。標準偏差の結果は統計的な有意差があり、低リスクな行動を学習できている根拠となっている。また、資産額については銘柄ごとのばらつきが比較的小さく、DQN より安定した投資行動の学習が見込める。

今後の展望として、比較手法が少ないため多くの類似研究が採用している DDPG[21] などの手法との比較や LSTM に置き換えることが可能であると考えている。

参考文献

- [1] Nicholas Tung Chan and Christian Shelton. An electronic market-maker. In *AI Memo 2001-005*,

- 2001.
- [2] Y Hilpisch. Deep learning in finance. In *arXiv:1602.06561*, 2016.
 - [3] 石原龍太. 多層ニューラルネットワークと ga を用いた topix 運用 ai. 第 19 回人工知能学会 金融情報学研究会, 2017.
 - [4] 加藤旺樹, 穴田一. 遺伝的プログラミングを用いたテクニカル指標による金融取引の戦略木構築. 第 24 回人工知能学会 金融情報学研究会, 2020.
 - [5] 上田翼, 東出卓朗. 人工知能を用いた金融政策予想と市場予測分布に基づく為替の投資戦略. 第 18 回人工知能学会 金融情報学研究会, 2017.
 - [6] 宮坂純也, 穴田一. 心理的要素を考慮した投資行動モデル. 第 18 回人工知能学会 金融情報学研究会, 2017.
 - [7] Jia WU, Chen WANG, Lidong XIONG, and Hongyong SUN. Quantitative trading on stock market based on deep reinforcement learning. In *IJCNN*, 2019.
 - [8] 小林弘幸, 和泉潔, 松島裕康, 坂地泰紀, 島田尚. 強化学習による高頻度取引戦略の構築. 第 24 回人工知能学会 金融情報学研究会, 2020.
 - [9] 常井祥太, 穴田一. Nt 倍率取引における深層強化学習を用いた投資戦略の構築. 第 22 回人工知能金融情報学研究会, 2019.
 - [10] Wonsup Shin, Seok-Jun Bu, and Sung-Bae Cho. Automatic financial trading agent for low-risk portfolio management using deep reinforcement learning. In *arXiv:1909.03278*, 2019.
 - [11] Zhuoran Xiong, Xiao-Yang Liu, Shan Zhong, Hongyang (Bruce) Yang, and Anwar Walid. Practical deep reinforcement learning approach for stock trading. In *NIPS 2018 Workshop on Challenges and Opportunities for AI in Financial Services*, 2018.
 - [12] Yifan Zhang, Peilin Zhao, Qingyao Wu, Bin Li, Junzhou Huang, and Minghui Tan. Cost-sensitive portfolio selection via deep reinforcement learning. In *arXiv:2003.03051*, 2020.
 - [13] Yunan Ye, Hengzhi Pei, Boxin Wang, Pin-Yu Chen, Yada Zhu, and Bo Li Jun Xiao. Reinforcement-learning based portfolio management with augmented asset movement prediction states. In *The Thirty-Fourth AAAI Conference on Artificial Intelligence*, 2020.
 - [14] W. Sharpe. The sharpe ratio. In *The Journal of Portfolio Management*, Vol. 1, pp. 49–58, 1994.
 - [15] Marc G. Bellemare, Will Dabney, and Remi Munos. A distributional perspective on reinforcement learning. In *ICML*, 2017.
 - [16] Will Dabney, Georg Ostrovski, David Silver, and Remi Munos. Implicit quantile networks for distributional reinforcement learning. In *ICML*, 2018.
 - [17] Zhengyao Jiang and Jinjun Liang. Cryptocurrency portfolio management with deep reinforcement learning. In *Intelligent Systems Conference (IntelliSys) 2017*, 2017.
 - [18] Zhengyao Jiang, Dixing Xu, and Jinjun Liang. A deep reinforcement learning framework for the financial portfolio management problem. In *arXiv:1706.10059*, 2017.
 - [19] Tetsuro Morimura, Masashi Sugiyama, Hisashi Kashima, Hirotaka Hachiya, and Toshiyuki Tanaka. Parametric return density estimation for reinforcement learning. In *In Proceedings of the Conference on Uncertainty in Artificial Intelligence*, 2010.
 - [20] Mnih, K. Kavukcuoglu, D. Silver, A. A. Rusu, M. G. Bellemare, J. Veness, M. Riedmiller, A. Graves, A. K. Fidjeland, G. Ostrovski, S. Petersen, C. Beattie, A. Sadik, I. Antonoglou, H. King, D. Kumaran, D. Wierstra, S. Legg, and D. Hassabis. Human-level control through deep reinforcement learning. In *Nature*, pp. 529–533, 2015.
 - [21] Timothy P. Lillicrap, Jonathan J. Hunt, Alexander Pritzel, Nicolas Heess, Tom Erez, Yuval Tassa, David Silver, and Daan Wierstra. Continuous control with deep reinforcement learning. In *arXiv:1509.02971*, 2015.

Estimation of agent-based models using Bayesian deep learning approach of BayesFlow

塩野剛志¹

Takashi SHIONO¹

¹ クレディ・スイス経済調査部

¹Credit Suisse Economic Research

Abstract: This paper examines the possibility of applying the novel likelihood-free Bayesian inference called BayesFlow proposed by Radev et al. (2020) to the estimation of agent-based models (ABMs). The BayesFlow is a fully likelihood-free approach, which directly approximates a posterior rather than a likelihood function, by learning an invertible probabilistic mapping that implements a Normalizing Flow between parameters and a standard Gaussian variables conditioned by data from simulations. This deep neural network-based method can mitigate the trilemma in the existing methods that all of the following three –higher flexibility, lower computational cost, and smaller arbitrariness cannot be achieved at the same time. As a result of the experiments, BayesFlow certainly achieved the superior accuracies in the validation task of recovering the ground-truth values of parameters from the simulated datasets, in case of a minimal stock market ABM. The method did not involve any extensive search of the hyperparameters or hand-crafted pre-selections of summary statistics, and took a significantly shorter computational time than an existing non-parametric MCMC approach.

1. Introduction

Agent-based models (ABM) have widely been used in the field of artificial markets and related-studies to investigate the microstructure of financial markets. In recent years, they also have increasingly been adopted in macroeconomic analysis, as an alternative to DSGE models. According to Grazzini et al. (2017), agent-based models are characterized by the following three features: (1) there are a multitude of agents that interact with each other and environment, (2) these agents are autonomous, in the sense that there is no central coordinator such as a Walrasian auctioneer nor the concealed time-axis in which the central coordinator works, and (3) aggregation is performed numerically.

Thus, an ABM allows for extreme flexibility in setting the behavioral patterns of each agent in heterogeneous manner. There is no prerequisite for rational expectation nor (ex-ante) market equilibrium, as the adaptive processes of learning and selection by agents are explicitly modeled. This assumption in agent's behavior is a fundamental difference between DSGE and ABM. Recent studies of agent-based macroeconomic modeling like Assenza et al. (2015) and Caiani et al. (2016) succeed to reproduce the stylized macroeconomic phenomena such

as the Phillips curve and the Oaken law from simulations of the ABM with adaptive agents. In other words, a rational agent was not a necessary condition for these observed phenomena of macroeconomy. Furthermore, their models precisely described the relationship between the financial sector and the real economy by explicitly modeling the balance sheet for each economic agent, which are therefore useful in discussing the impact on real economy from prudent policies on financial institutions. Because of its flexibility, ABMs are increasingly being understood for their usefulness as a complement to DSGE and will continue to be applied to various economic phenomena.

However, it has often been pointed out that an ABM has its weakness in the lack of empirical validation (Gallegati & Richiardi, 2009). The parameters in an ABM are usually calibrated manually to make the model's simulation outputs reproduce some particular characteristics of economic observables (e.g. fat-tail distribution or volatility clustering in stock return). In response to this challenge, studies to statistically estimate the parameters of ABM have recently begun.

Against these backgrounds, this paper adopts a novel likelihood-free Bayesian inference called BayesFlow proposed by Radev et al. (2020) for the statistical

estimation of ABMs. This method can mitigate the trilemma in the existing methods that all of the following three –higher flexibility, lower computational cost, and smaller arbitrariness cannot be achieved at the same time.

The BayesFlow is a fully likelihood-free approach, which directly approximates a Bayesian posterior rather than a likelihood function. This method is highly flexible, only requiring the ability to output simulation data from a mathematical forward model, and has an asymptotic theoretical guarantee for sampling from the true posterior without any specific assumption on the shape of the target posterior or prior. Hence, it does not need to presume ergodicity or stationarity of simulated time series of a model. Indeed, Radev et al. (2020) showed high accuracies of the BayesFlow even in the cases of potentially chaotic (the Ricker population model) and non-ergodic (the Levy-Flight model) mathematical models.

Secondly, in contrast to the typical likelihood-free methods such as Approximate Bayesian Computation, BayesFlow does not involve discretionary pre-selections or hand-crafted design in the critical parts of inference. It accompanies the learnable summary network which can compress variable-length potentially large dimensional inputs into fixed-length small dimensional summary statistics. Namely, a researcher does not need to pre-select specific moments of specific observables as a hand-crafted summary statistics.

Finally, it is computationally efficient, particularly in the case that repeated inferences with different observation datasets are needed. BayesFlow realizes amortized inference, where estimation is split into a computationally intensive training phase, and a much cheaper inference phase. In the training phase, BayesFlow tries to learn a model to output an approximate posterior that works properly for any possible observation sequence. Then, evaluating the trained model over a specific observation dataset is computationally very cheap, so that the upfront training efforts amortizes over multiple inferences.

In the next section, I explain a basic structure of the BayesFlow comparing with other related methodologies. Then, the procedure and results of validation are presented in Section 3, before discussing the advantages and limitations with conclusion.

2. Methods

2.1. Notation

In the following, I denote the data simulated from

agent-based model as $X_{1:T} \equiv (X_1, \dots, X_T) \in \mathbb{R}^K \times \dots \times \mathbb{R}^K$, where individual X_t is a vector of observable variables in a model with its dimension being denoted as K . The number of observation points in a dataset is denoted as T to make it clear that simulation outputs from an ABM are usually multivariate time-series. Simulated data is also expressed as $X_{1:T}(\theta)$ when it needs to be emphasized that the data is generated from the ABM with parameters θ . Actual observed data or test data will be expressed with a superscript as $X_{1:T}^o$. Parameters of a forward model (i.e. ABM) are represented as a vector $\theta \in \mathbb{R}^d$.

2.2. Agent-Based Model

The state of the whole system of an agent-based model at time t is described by the collection of all micro-states of individual agent i in time period t as $S_t \equiv \{s_{i,t}\}_{i=1}^N$. The evolution or the law of transition of each agent's state is expressed as:

$$s_{i,t} = f_i(s_{i,t-1}, \xi_t, \theta), \quad (1)$$

where f_i is an agent-wise state transition function, taking values in \mathbb{R}^L . $\xi_t \equiv \{\zeta_{i,t}\}_{i=1}^N$ is a vector to bundle all stochastic elements. The functions f reflect the detailed modelling of agent's learning, selection and interaction behavior in an ABM, which are typically heterogeneous and accompanying discontinuities such as *if-else* statements.

Aggregate observable variables X_t are then be defined over S_t :

$$X_t = m(S_t), \quad (2)$$

where a function m aggregates and transforms the collection of micro-states into observable variables X_t . Combining the state transition f_i in Eq.(1) and observation m in Eq.(2), a simulation data generation function G of a ABM can be defined as follows:

$$X_{1:T} = G(\theta, \xi_{1:T}) \text{ with } \xi_{1:T} \sim p(\xi). \quad (3)$$

This function G effectively corresponds to one shot of ABM simulation run with the parameters θ and the stochastic elements $\xi_{1:T}$ sampled from the known distribution¹.

2.3. Bayesian Inference on Agent-Based Model

In Bayesian inference, the posterior defined below contains all information about θ extractable from a series of observations $X_{1:T}$:

$$p(\theta|X_{1:T}) = \frac{p(X_{1:T}|\theta)p(\theta)}{\int p(X_{1:T}|\theta)p(\theta) d\theta}.$$

Even when a closed-form expression of the posterior is unobtainable, various sampling schemes from the posterior such as MCMC or Sequential Monte Carlo (SMC) are applicable, as long as the likelihood of a forward model $p(X_{1:T}|\theta)$ can easily be evaluated by the actual observations $X_{1:T}^o$ together with any prior $p(\theta)$, such that:

$$p(\theta|X_{1:T}^o) \propto \mathcal{L}(\theta; X_{1:T}^o) p(\theta).$$

In case of most practical-scale ABMs, however, the likelihood function $\mathcal{L}(\theta; X_{1:T}^o) \equiv p(X_{1:T}^o|\theta)$ is generally intractable, in other words, not available in closed-form. This is the central challenge in Bayesian inference on an ABM. The existing study by Grazzini et al. (2017) tried to approximate the likelihood function, and apply standard posterior sampling schemes such as MCMC with the approximated likelihood. They limited their scope to ergodic ABMs, to ensure simulation time series generated from a model remain stationary around the deterministic steady state level $g^*(\theta)$ as:

$$X_{1:T} = \{g^*(\theta) + \epsilon_t\}_{t=1}^T.$$

In that case, a likelihood of the observation series $X_{1:T}$ is just products of a time-invariant density function: $p(X_{1:T}|\theta) = \prod_t f(X_t|\theta)$.

One approach of them is to approximate this density function by (1) non-parametric way of Kernel Density Estimation: $f(X_t|\theta) \approx \hat{f}(X_t|\theta) = KDE(X_{1:T}(\theta))$. This is simply a histogram smoothing of the simulation data generated from an ABM with a set of parameters. Another

approach proposed by the study is to use (2) a Gaussian density $f(X_t|\theta) \approx N(g^*(\theta), \sigma_\epsilon^2 \mathbb{I}_K)$ rather than KDE. The use of a parametric distribution can clearly reduce computational costs, which could be prohibitive in case of multivariate KDE, at the expense of flexibility or expressive power. In both cases, a likelihood of the parameters is calculated by evaluating the constructed density at observed data points: $\mathcal{L}(\theta; X_{1:T}^o) = \prod_t \hat{f}(X_t^o|\theta)$. They also applied (3) Approximate Bayesian Computation that directory approximates a likelihood function by a 1-0 indicator function: $p(X_{1:T}^o|\theta) \approx \mathbb{I}(d[\mu(X_{1:T}(\theta)), \mu(X_{1:T}^o)] < h)$, where $\mu(\cdot)$ is a summary statistics, $d[\cdot, \cdot]$ is a distance measure, and h is a threshold for distance. This approach could potentially perform well in the wider class of ABMs with a relatively cheaper computational burden, only if pre-selection or hand-crafted design of an indicator function is appropriate to approximate the target likelihood. However, such a good pre-selection is difficult in practice.

2.4. Likelihood-free Approach: BayesFlow

In this paper, I opt to adopt a novel likelihood-free Bayesian inference of *BayesFlow* proposed by Radev et al. (2020). This can mitigate the trilemma in the existing methods that all of the following three – higher flexibility, lower computational cost, and smaller arbitrariness cannot be achieved at the same time.

BayesFlow is fully likelihood-free approach, which directly approximates a posterior $p(\theta|X_{1:T})$, rather than a likelihood function $p(X_{1:T}|\theta)$. It does not need to presume ergodicity of ABM, or stationarity of simulated time series. This likelihood-free approach only requires the ability to output simulation data from a forward model, which generates samples of observable variables by a deterministic function G of parameters θ and independent noises ξ with known distribution as:

$$X_t \sim p(X|\theta) \Leftrightarrow X_t = g(\theta, \xi_t) \text{ with } \xi_t \sim p(\xi),$$

or T samples simultaneously as:

$$X_{1:T} \sim p(X_{1:T}|\theta) \Leftrightarrow X_{1:T} = G(\theta, \xi_{1:T}) \text{ with } \xi_{1:T} \sim p(\xi). \quad (4)$$

sampled from the given distribution as stochastic elements.

¹ Initial micro-states $S_0 = \{s_{i,0}\}_{i=1}^N$ could be included in parameters or

Here, the likelihood $p(X_{1:T}|\theta)$ is only implicitly defined and need not be available in closed-form. Therefore, BayesFlow can seamlessly be applied to an agent-based model since a simulation data generation function G of an ABM in Eq. (3) meets this sampling requirement.

The goal of BayesFlow is to approximate the target posterior by the parameterized approximate posterior as accurately as possible:

$$p(\theta|X_{1:T}) \approx p_\phi(\theta|X_{1:T}).$$

BayesFlow utilizes a conditional invertible neural network (cINN) to this objective. In other word, the cINN constitutes an invertible function $f_\phi: \mathbb{R}^d \rightarrow \mathbb{R}^d$ parameterized by a vector of parameters ϕ , for which the inverse $f_\phi^{-1}: \mathbb{R}^d \rightarrow \mathbb{R}^d$ exists. The approximate posterior p_ϕ is then reparameterized in terms of a cINN f_ϕ that implements a Normalizing Flow (Rezende & Mohamed, 2015) between θ and a standard Gaussian latent variable z :

$$\theta \sim p_\phi(\theta|X_{1:T}) \Leftrightarrow \theta = f_\phi^{-1}(z; X_{1:T}) \text{ with } z \sim N(z|0, \mathbb{I}_d).$$

Namely, the cINN is to be trained so that outputs of its inverse f_ϕ^{-1} follow the target posterior $p(\theta|X_{1:T})$.

2.5. Learning the Posterior

The training objective for the cINN is thus to minimize the Kullback-Leibler (KL) divergence between the target and the model-induced approximate posterior for all possible series of observable variables $X_{1:T}$ as follows:

$$\begin{aligned} \hat{\phi} &= \operatorname{argmin}_{\phi} \mathbb{E}_{X_{1:T} \sim p(X;T)} \left[\mathbb{KL}[p(\theta|X_{1:T}) || p_\phi(\theta|X_{1:T})] \right] \\ &= \operatorname{argmin}_{\phi} \mathbb{E}_{X_{1:T} \sim p(X;T)} \left[\mathbb{E}_{\theta \sim p(\theta|X_{1:T})} [\log p(\theta|X_{1:T}) \right. \\ &\quad \left. - \log p_\phi(\theta|X_{1:T})] \right] \\ &= \operatorname{argmax}_{\phi} \mathbb{E}_{X_{1:T} \sim p(X;T)} \left[\mathbb{E}_{\theta \sim p(\theta|X_{1:T})} [\log p_\phi(\theta|X_{1:T})] \right] \\ &= \operatorname{argmax}_{\phi} \iint p(X, \theta; T) \log p_\phi(\theta|X_{1:T}) dX_{1:T} d\theta \end{aligned}$$

Then, since the forward transmission of cINN outputs by definition a standard Gaussian latent variable

$f_\phi(\theta; X_{1:T}) = z$, the density transformation law of random variable enables the reparameterization of the approximate posterior p_ϕ in terms of cINN f_ϕ as follows:

$$p_\phi(\theta|X_{1:T}) = p\left(z = f_\phi(\theta; X_{1:T})\right) \left| \det \left(\frac{\partial f_\phi(\theta; X_{1:T})}{\partial \theta} \right) \right|.$$

This is a fundamental operation of a Normalizing Flow. Incorporating this fact, the training objective can be re-written as:

$$\begin{aligned} \hat{\phi} &= \operatorname{argmax}_{\phi} \iint p(X, \theta; T) \left\{ \log p\left(f_\phi(\theta; X_{1:T})\right) \right. \\ &\quad \left. + \log \left| \det J_{f_\phi} \right| \right\} dX_{1:T} d\theta, \end{aligned} \quad (5)$$

where J_{f_ϕ} stands for $\partial f_\phi(\theta; X_{1:T}) / \partial \theta$ (the Jacobian of f_ϕ evaluated at θ and $X_{1:T}$).

Even in the likelihood-free setting, it is easy to generate samples from $(\theta^{(j)}, X_{1:T}^{(j)}) \sim p(X, \theta; T)$ with a forward model G and the prior $p(\theta)$ as shown in Eq.(4). Utilizing the M sets of data-generating parameters and corresponding simulated data $\{(\theta^{(j)}, X_{1:T}^{(j)})\}_{j=1}^M$, the expectation in Eq.(5) is approximated by the Monte-Carlo estimate as follows:

$$\begin{aligned} \hat{\phi} &= \operatorname{argmax}_{\phi} \frac{1}{M} \sum_{j=1}^M \log p\left(f_\phi\left(\theta^{(j)}; X_{1:T}^{(j)}\right)\right) \\ &\quad + \log \left| \det J_{f_\phi}^{(j)} \right|. \end{aligned} \quad (6)$$

By taking negative of Eq.(6) and using the fact that $\log N(z|0, \mathbb{I}_d) \propto -\frac{1}{2} \|z\|_2^2$, the training objective for cINN now becomes:

$$\hat{\phi} = \operatorname{argmin}_{\phi} \mathcal{L}(\phi)$$

with

$$\mathcal{L}(\phi) = \frac{1}{M} \sum_{j=1}^M \left(\frac{\|f_\phi(\theta^{(j)}; X_{1:T}^{(j)})\|_2^2}{2} - \log \left| \det J_{f_\phi}^{(j)} \right| \right).$$

(7)

The $\mathcal{L}(\phi)$ is a loss function for this posterior approximation task, which can be minimized with any stochastic gradient descent algorithm.

2.6. Summary Network

When training cINN with simulated datasets, Radev et al. (2020) recommended to use a summary network f_ψ to construct an estimate of sufficient statistics that captures all information about θ contained in $X_{1:T}$ in a fixed-size representation $\tilde{X} = f_\psi(X_{1:T})$. Since the number of observations or time points usually varies in a practical conduct of Bayesian inference, the method needs to be generalized to data of variable size T . Furthermore, the training of cINN could be more efficient with the sort of dimensionality reduction as datasets might exhibit some redundancies without any pre-selection of observable variables.

BayesFlow is designed to use a bidirectional LSTM (Graves & Schmidhuber, 2005) as a summary network for time series-data. LSTM network is well known to be able to effectively deal with the long-memory (i.e. non-ergodic and non-stationary) serial data such as natural language sentences. Indeed, Radev et al. (2020) showed high accuracies² of BayesFlow even in the tasks to estimate the parameters of potentially chaotic (the Ricker population model) and non-ergodic (the Levy-Flight model) mathematical models.

In the context of ABM estimation, this feature of BayesFlow can unleash full flexibility of agent-based models, as it does no longer require ergodicity or stationarity of its output time series.

The parameters of the summary network are jointly optimized with those of the cINN. Hence, the training objective is now finalized as:

$$\hat{\phi}, \hat{\psi}$$

$$= \operatorname{argmax}_{\phi, \psi} \mathbb{E}_{X_{1:T} \sim p(X;T)} \left[\mathbb{E}_{\theta \sim p(\theta|X_{1:T})} \left[\log p_\phi \left(\theta | f_\psi(X_{1:T}) \right) \right] \right]$$

² They tested accuracy of recovering the ground-truth parameter values

$$= \operatorname{argmin}_{\phi, \psi} \mathcal{L}(\phi, \psi)$$

with

$$\mathcal{L}(\phi, \psi) = \frac{1}{M} \sum_{j=1}^M \left(\frac{\left\| f_\phi \left(\theta^{(j)}; f_\psi(X_{1:T}^{(j)}) \right) \right\|_2^2}{2} - \log \left| \det J_{f_\phi}^{(j)} \right| \right). \quad (8)$$

2.7. Structure of Invertible Networks

The cINN is constructed as a chain of multiple conditional affine coupling blocks (cACBs). The idea of an ACB was originally introduced by Dinh et al. (2017), which implements an invertible non-linear transformation: $f_{acb}: \mathbb{R}^d \rightarrow \mathbb{R}^d$ and $f_{acb}^{-1}: \mathbb{R}^d \rightarrow \mathbb{R}^d$. Each ACB consists of four separate fully connected neural networks denoted as $s_1(\cdot), s_2(\cdot), t_1(\cdot), t_2(\cdot)$. These internal networks need not be invertible since they are only evaluated in a forward direction during both the forward and the inverse operations of an ACB. By denoting input vector of f_{acb} as U and output vector as V , the forward and inverse transformations of the vectors are expressed as $f_{acb}(U) = V$ and $f_{acb}^{-1}(V) = U$. This invertibility is realized by splitting the input vector into two parts $U = (U_1, U_2)$ with $U_1 = u_{1:d/2}$ and $U_2 = u_{d/2+1:d}$ and performing the following operations on the split input:

$$\begin{aligned} V_1 &= U_1 \odot \exp(s_1(U_2)) + t_1(U_2) \\ V_2 &= U_2 \odot \exp(s_2(U_1)) + t_2(U_1) \\ V &= (V_1, V_2) \end{aligned}$$

where \odot represents element-wise multiplication. Then, the inverse operation is given by:

$$\begin{aligned} U_1 &= (V_2 - t_2(U_1)) \odot \exp(s_2(U_1)) \\ U_2 &= (V_1 - t_1(U_2)) \odot \exp(s_1(U_2)) \end{aligned}$$

This formulation ensures that the Jacobian of cINN is a strictly upper or a lower triangular matrix and therefore its

from out-of-sample simulation data.

determinant ($\det J_{f_\phi}$) is quite cheap to compute, which is an important feature when using it in a Normalizing Flow. Then, ACB is augmented to take the summary statistics \tilde{X} as a conditioning input, so as to switch the pattern of bidirectional transformations along with the values of observations $X_{1:T}$ as follows:

$$V_1 = U_1 \odot \exp \left(s_1(U_2, \tilde{X}) \right) + t_1(U_2, \tilde{X})$$

$$V_2 = U_2 \odot \exp \left(s_2(U_1, \tilde{X}) \right) + t_2(U_1, \tilde{X}).$$

This structure is a conditional affine coupling block (cACB). BayesFlow stacks the multiple cACBs to make the whole neural network architecture (i.e. cINN) expressive enough to implement a potentially complex mapping between the d -dimensional vector of parameters θ and a same dimensional vector of unit Gaussian variables z . Eventually, the entire conditional invertible neural network (cINN) is expressed as a function $z = f_\phi(\theta; \tilde{X})$, together with the inverse operation $\theta = f_\phi^{-1}(z; \tilde{X})$.

2.8. Amortized Inference

For most Bayesian inference algorithms, the entire estimation process must be repeated from scratch when dealing with the different observation sequences (e.g. $X_{1:T}^{(i)}$ and $X_{1:T}^{(j)}$ with $i \neq j$). In contrast, Bayes flow realizes *amortized inference*, where estimation is split into a computationally expensive training phase, and a much cheaper inference phase. In the training phase, BayesFlow tries to learn a model to output an approximate posterior $\hat{p}_\phi(\theta|X_{1:T})$ that works well for any possible observation sequence $X_{1:T}$. Namely, cINN is trained up front so that its inverse operation outputs samples from an approximate posterior given observations: $f_\phi^{-1}(z|X_{1:T}^o) = \hat{\theta} \sim p_\phi(\theta|X_{1:T}^o)$ with $z \sim N(0, \mathbb{I}_d)$. Hence, evaluating the trained model over a specific observation dataset $X_{1:T}^o$ is

computationally very cheap, so that the upfront training efforts amortizes over multiple inferences.

Putting it all together, a whole procedure of Bayesian inference with the BayesFlow method is summarized as Algorithm 1.

```

1 :   Training (with online simulation data generations)
2 :   repeat
3 :       Sample sequence length of observations:  $T \sim U(T_{min}, T_{max})$ 
4 :       Sample a batch of parameters from prior:  $\{\theta^{(j)}\}_{j=1}^M \sim p(\theta)$ 
5 :       Simulate  $M$  data sets size  $T$  via the data generation function Eq.(4):  $\{X_{1:T}^{(j)} = G(\theta^{(j)}, \xi_{1:T})\}_{j=1}^M$ 
6 :       Pass  $\{X_{1:T}^{(j)}\}_{j=1}^M$  into summary network to obtain summary statistics:  $\{\tilde{X}^{(j)} = f_\psi(X_{1:T}^{(j)})\}_{j=1}^M$ 
7 :       Pass  $\{(\theta^{(j)}, X_{1:T}^{(j)})\}_{j=1}^M$  into cINN to obtain  $\{z^{(j)} = f_\phi(\theta^{(j)}; \tilde{X}^{(j)})\}_{j=1}^M$ 
8 :       Compute loss according to Eq.(8)
9 :       Update neural network parameters  $\phi, \psi$  via backpropagation
10 :   until convergence to  $\hat{\phi}, \hat{\psi}$ 
11 :
12 :   Inference (given observed or test data  $X^o$ )
13 :   Compute summary of the data  $\tilde{X}^o = f_\psi(X_{1:T}^o)$ 
14 :   for  $l = 1, \dots, L$  do
15 :       Sample  $z^{(l)} \sim N(0, \mathbb{I}_d)$ 
16 :       Compute inverse  $\theta^{(l)} = f_\phi^{-1}(z^{(l)}; \tilde{X}^o)$ 
17 :   end
18 :   Return  $\{\theta^{(l)}\}_{l=1}^L$  as a sample from  $p(\theta|X^o)$ 
    
```

Algorithm 1: Bayesian inference with the BayesFlow method

3. Experiments

3.1. Training

All networks were implemented in Python using the *pytorch* library and trained on a single-GPU machine equipped with NVIDIA(R) GTX1050Ti graphics card. Stochastic gradient descent is implemented by Adam optimizer with default setting of *pytorch* package (learning rate of 0.001). Following the original paper of BayesFlow (Radev et al., 2020), *online learning* approach is taken, where data are simulated from an ABM on demand. As the network never experiences the same input data twice, training can continue as long as the loss keeps decreasing without any concern on overfitting in the classical sense. I performed total 40 000 online update steps in the training with each step using a new pair of parameters and simulated timeseries from an ABM. Incidentally, in the both of two examples explained below, just around 20 000 online steps were enough for the neural networks to reach convergence. Meanwhile, if one simulation takes a high computational cost, a researcher

can opt to perform *off-line learning* approach, in which the fixed number of samples according with the computational budget are generated ex-ante from an ABM, and then the widely parallelized batch learning should be performed on GPU. In any case, the converged networks can repeatedly be used to perform amortized inference on a different observation dataset. As for the hyperparameters, I opt to use a default BayesFlow with 5 ABCs, and a summary vector of size 32 obtained through 3-layer bidirectional LSTM without extensive tune-up.

3.2. Performance Validation

To evaluate the performance of applying BayesFlow to ABM estimation, I opt to use the following two simple metrics defined between the ground-truth parameters $\{\theta^{(l)}\}_{l=1}^L$ which generate the test simulation datasets $\{X_{1:T}^o(\theta^{(l)})\}_{l=1}^L$ and the estimated parameters $\{\hat{\theta}^{(l)}\}_{l=1}^L$ reproduced from the test datasets. The number of test estimations is one hundred: $L = 100$.

(1) Normalized Rooted Mean Squared Error: $NRMSE =$

$$\sqrt{\frac{\sum_{l=1}^L (\theta^{(l)} - \hat{\theta}^{(l)})^2}{\theta_{max} - \theta_{min}}}$$

(2) Coefficient of determination: $R^2 = 1 -$

$$\frac{\sum_{l=1}^L (\theta^{(l)} - \hat{\theta}^{(l)})^2}{\sum_{l=1}^L (\theta^{(l)} - \bar{\theta})^2}$$

The competing benchmark for the validation is the non-parametric KDE with MCMC (a random walk Metropolis-Hastings algorithm) proposed by Grazzini et al. (2017), in which 4 000 iterations are conducted for each estimation procedure.

In the actual experiments, I opt to perform Bayesian inference on the ABM: the minimal stock market ABM with 1 parameter which was originally proposed by Cliff & Bruten (1997), taken up for the estimation experiments by Grazzini & Richiardi (2015) and Grazzini et al. (2017).

3.3.A Minimal Stock Market ABM with 1

parameter


This minimal stock market ABM is populated by sellers and buyers who adjust their profit margin $\mu_{i,t}$, and set price for a bid or ask limit orders by watching an order book of market. The limit price of trader i in period t is updated as the following rule:

$$\begin{aligned} p_{i,t+1} &= v_i(1 + \mu_{i,t+1}), \\ \mu_{i,t+1} &= (p_{i,t} + \Delta_{i,t})/v_i - 1, \\ \Delta_{i,t} &= \beta(\tau_{i,t} - p_{i,t}), \end{aligned}$$

where v_i is a trader specific volume of order, $\tau_{i,t}$ is an implicit target price of a trader that is hiked if the last trade occurred at a higher price, and lowered otherwise. The behavioral parameter β , common to all traders, is the sensitivity of how traders react to the existing gap between the target price $\tau_{i,t}$ and the current price $p_{i,t}$. The higher this β value, the more sensitive traders are to the prices of the others, resulting in more elastic market.

In the validation procedure, for each separate trial of $l = 1, \dots, 100$, I tried to recover a ground-truth value of the parameter $\beta^{(l)}$ from the simulated time series of the market price from this ABM (i.e. $X_{1:T}^o(\beta^{(l)})$) by using BayesFlow and KDE-MCMC, respectively. The values of ground-truth parameter for the test trials are sampled from uniform distribution: $\beta^{(l)} \sim U(0,1)$. The prior distribution for BayesFlow and KDE-MCMC is the same with this: $U(0,1)$.

The results are depicted in Table 1 and BayesFlow



KDE-MCMC





Figure 1. While the both methods fairly succeeded to

recover the ground-truth parameter from the simulated dataset in most trials, the overall precision measured by NRMSE and R2 is clearly higher in BayesFlow.

	BayesFlow	KDE-MCMC
NRMSE	0.007	0.058
R2	1.000	0.993

Table 1: Performance results on a minimal stock market ABM.

BayesFlow



KDE-MCMC




Figure 1: Parameter recovery plots where x-axis takes value of the estimated parameter and y-axis is the ground-truth parameter ($L=100$).

As I performed 100 separate estimations to calculate the validation metrics, the difference in computational costs became significant between the amortized inference of BayesFlow and the case-by-case inference of KDE-MCMC, even in the minimal 1 parameter ABM. One simulation run of the ABM with the 500 observation periods (where the first 500 periods were discarded as burn-in) takes 1.5 secs. In KDE-MCMC, the likelihood approximation and the Metropolis-Hastings update cost additional 2.5 secs. As I conducted 4 000 iterations in the M-H algorithm for each estimation, the total computational time for the 100 separate estimations was massive 444 hours ($1\,600\,000 = 100 \times 4\,000 \times (1.5 + 2.5)$ secs). I inevitably parallelized the CPU core processes over the separable 100 estimations. On the other hand, BayesFlow took much shorter 18.9 hours (68 152 secs) in

total. While the training phase with 40 000 online training steps costs 68 000 secs as one step takes 1.7 ($=1.5$ of data generation + 0.2 of SGD) secs, the amortized inference with the 100 separate test datasets only takes 152 (1.5×100 of test data generation + 2 of inference) secs. Furthermore, as already mentioned above, the training of BayesFlow actually reached the convergence with much fewer steps of 20 000, meaning that computational time could be shortened by half. Meanwhile, it looks unrealistic to cut MCMC iterations to less than 4 000 in order to obtain the accepted samples of more than 1 000.

4. Concluding Remarks

This paper examines the possibility of applying the novel likelihood-free Bayesian inference called BayesFlow proposed by Radev et al. (2020) to the estimation of agent-based models (ABMs). The BayesFlow is a fully likelihood-free approach, which directly approximates a posterior rather than a likelihood function, by learning an invertible probabilistic mapping that implements a Normalizing Flow between parameters and a standard Gaussian variables conditioned by data from simulations. This deep neural network-based method can mitigate the trilemma in the existing methods that all of the following three –higher flexibility, lower computational cost, and smaller arbitrariness cannot be achieved at the same time. As a result of the experiments, BayesFlow certainly achieved the superior accuracies in the validation task of recovering the ground-truth values of parameters from the simulated datasets, in a minimal stock market ABM. The method did not involve any extensive search of the hyperparameters or hand-crafted pre-selections of summary statistics, and took a significantly shorter computational time than an existing non-parametric MCMC approach.

References

- [1] Assenza, T., Delli Gatti, D., & Grazzini, J. (2015). Emergent dynamics of a macroeconomic agent based model with capital and credit. *Journal of Economic Dynamics and Control*, 50, 5–28. <https://doi.org/10.1016/j.jedc.2014.07.001>
- [2] Caiani, A., Godin, A., Caverzasi, E., Gallegati, M., Kinsella, S., & Stiglitz, J. E. (2016). Agent based-stock flow consistent macroeconomics: Towards a benchmark model. *Journal of Economic Dynamics and Control*, 69, 375–408. <https://doi.org/10.1016/j.jedc.2016.06.001>
- [3] Cliff, D., & Bruten, J. (1997). Zero is not enough: on the lower limit of agent intelligence for continuous double auction markets. In *HP Laboratories Technical Report (Issues 97–141)*.
- [4] Dinh, L., Sohl-Dickstein, J., & Bengio, S. (2017, May 27). Density estimation using real NVP. 5th International Conference on Learning Representations, ICLR 2017 - Conference Track Proceedings. <http://arxiv.org/abs/1605.08803>
- [5] Gallegati, M., & Richiardi, M. G. (2009). Agent Based Models in Economics and Complexity. In *Encyclopedia of Complexity and Systems Science* (pp. 200–224). Springer New York. https://doi.org/10.1007/978-0-387-30440-3_14
- [6] Ghonghadze, J., & Lux, T. (2016). Bringing an elementary agent-based model to the data: Estimation via GMM and an application to forecasting of asset price volatility. *Journal of Empirical Finance*, 37, 1–19. <https://doi.org/10.1016/j.jempfin.2016.02.002>
- [7] Graves, A., & Schmidhuber, J. (2005). Framewise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural Networks*, 18(5–6), 602–610. <https://doi.org/10.1016/j.neunet.2005.06.042>
- [8] Grazzini, J., & Richiardi, M. (2015). Estimation of ergodic agent-based models by simulated minimum distance. *Journal of Economic Dynamics and Control*, 51, 148–165. <https://doi.org/10.1016/j.jedc.2014.10.006>
- [9] Grazzini, J., Richiardi, M. G., & Tsionas, M. (2017). Bayesian estimation of agent-based models. *Journal of Economic Dynamics and Control*, 77, 26–47. <https://doi.org/10.1016/j.jedc.2017.01.014>
- [1 0] Lamperti, F., Roventini, A., & Sani, A. (2018). Agent-based model calibration using machine learning surrogates. *Journal of Economic Dynamics and Control*, 90, 366–389. <https://doi.org/10.1016/j.jedc.2018.03.011>
- [1 1] Lux, T. (2018). Estimation of agent-based models using sequential Monte Carlo methods. *Journal of Economic Dynamics and Control*, 91, 391–408. <https://doi.org/10.1016/j.jedc.2018.01.021>
- [1 2] Radev, S. T., Mertens, U. K., Voss, A., Ardizzone, L., & Köthe, U. (2020). BayesFlow: Learning complex stochastic models with invertible neural networks. <http://arxiv.org/abs/2003.06281>
- [1 3] Rezende, D. J., & Mohamed, S. (2015). Variational Inference with Normalizing Flows. 32nd International Conference on Machine Learning, ICML 2015, 2, 1530–1538. <http://arxiv.org/abs/1505.05770>