

# 金融情報学研究会(第22回)

日時 2019年3月3日(日)

会場 成蹊大学 6号館401教室

**SIG-FIN**  
JSAI Special Interest Group on  
Financial Informatics

人工知能学会  
金融情報学研究会

## 第22回 人工知能学会 金融情報学研究会 (SIG-FIN)

2019年3月3日(日) 成蹊大学 6号館401教室

01. 投機ゲームにおける価格変動パターン ..... 1  
片平啓(東京大学), 鈔宇通(復旦大学), 陳昱(東京大学)
02. 板の中心値段からの距離と約定の関連分析 ..... 6  
幸田茂樹, 吉田健一(筑波大学)
03. イナゴタワーから分かる投資家行動～VPIN を用いた仕手株の分析～ ..... 13  
吉川満(大和大学)
04. ビットコインにおけるラフボラティリティとラフ取引高 ..... 19  
高石哲弥(広島経済大学)
06. インフルエンサーのツイートを用いた暗号資産の価格変化予測 ..... 25  
山本寛史, 坂地泰紀, 松島裕康(東京大学), 山下雄己, 大澤恭平(電通国際情報サービス),  
和泉潔, 島田尚(東京大学)
07. LDA を用いた株式掲示板の投稿メッセージによる恐怖指数上昇予測の提案 ..... 31  
佐々木皓大(東京都市大学), 諏訪博彦(奈良先端科学技術大学院大学), 小川祐樹(立命館大学),  
梅原英一(東京都市大学), 山下達雄, 坪内孝太(Yahoo!JAPAN 研究所)
08. 金融機関のテキストデータに基づく企業の業績要因の抽出 ..... 37  
近藤浩史, 大沼俊輔(日本総合研究所), 中込祐平, 遠藤公志郎, 三橋尚文,  
佐藤雪子(三井住友銀行), 酒井浩之(成蹊大学)
09. アナリストレポートを用いた中長期株価動向推定 ..... 42  
堅木聖也, 坂地泰紀, 和泉潔(東京大学), 石川康, 笠岡恒平(日興アセットマネジメント)
10. 新聞記事からのテキストマイニングによる因果関係を考慮したアナリストレポートの自動要約文生成 ... 48  
高嶺航, 坂地泰紀, 和泉潔, 松島裕康, 島田尚(東京大学), 清水康弘(野村証券)
11. アナリストレポートと企業業績の関係解析 (第一報) ..... 53  
北島良三, 酒井浩之(成蹊大学), 上村龍太郎(東海大学), 坂地泰紀(東京大学), 平松賢士,  
栗田昌孝(アイフィスジャパン, 金融データソリューションズ)
12. 対話型 AI を活用した、投資知識などの推定 ..... 57  
河合継(クリスタルメソッド), 新田翔(クリスタルメソッド, 東京理科大学), 木村祐輔(クリスタルメソッド),  
西山昇(千葉商科大学)

13. 関連記事を用いた市況分析コメントの自動生成 .....	61
酒井浩之(成蹊大学), 坂地泰紀, 和泉潔(東京大学), 松井藤五郎(中部大学), 入江圭太郎(三菱UFJ 国際投信)	
14. 経済因果チェーン検索のシステム紹介と応用 .....	67
和泉潔, 坂地泰紀(東京大学)	
15. 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 .....	71
常井祥太, 穴田一(東京都市大学)	
16. LSTM による時系列予測と株式投資戦略への応用 .....	77
松本健, 牧本直樹(筑波大学)	
17. 日米イールドカーブの連動性を用いた機械学習に基づく日本国債の長期金利予測 .....	81
水門善之(東京大学, 野村証券金融経済研究所), 坂地泰紀, 和泉潔, 島田尚, 松島裕康(東京大学)	
18. テクニカル指標による金融取引の戦略的構築 .....	88
加藤旺樹, 穴田一(東京都市大学)	
19. 財務指標とマクロ経済インデックスに基づく中小企業のデフォルト予測 .....	92
大石敬昌, 田中利幸(京都大学)	
20. オプションアプローチによる中小企業の現預金残高分布の推測 .....	100
薄井研二(freee)	
21. 銀行間と企業間の多層ネットワークシミュレーションを用いた企業投資の影響分析 .....	104
濱脇諒(東京大学), 尾崎順一(東工大), 和泉潔, 島田尚, 松島裕康, 坂地泰紀(東京大学)	
22. 人工市場を用いた金融市場流動性に影響を与える要因の調査 .....	108
益田裕司(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)	
23. シミュレーションによるインデックス投資の市場価格形成への影響分析 .....	116
松浦出, 和泉潔, 坂地泰紀, 松島裕康, 島田尚(東京大学)	
24. Verification for Liquidity of Marketable Securities via Artificial Market Approach .....	120
曹治平(東京工業大学), 水田孝信(スパークス・アセット・マネジメント)	
25. 遺伝的プログラミングによる市場価格変動の時系列モデルの構築 .....	126
吉村勇志, 陳昱(東京大学)	
26. 流動性リスク管理による銀行ネットワーク安定化のシミュレーション分析 .....	131
曾根泰平, 和泉潔, 坂地泰紀, 松島裕康, 島田尚(東京大学)	

# 投機ゲームにおける価格変動パターン

## On Patterns of Price Change in Speculation Game

片平啓<sup>1\*</sup>      鈔宇通<sup>2</sup>      陳昱<sup>1</sup>  
Kei Katahira<sup>1</sup>    Yutong Chao<sup>2</sup>    Yu Chen<sup>1</sup>

<sup>1</sup> 東京大学大学院新領域創成科学研究科

<sup>1</sup> Graduate School of Frontier Sciences, The University of Tokyo

<sup>2</sup> 复旦大学物理系

<sup>2</sup> Department of Physics, Fudan University

**Abstract:** In this study, the statistics of price change patterns is investigated firstly in Speculation Game (an agent-based market model characterized with round-trip trades), then in several real financial instruments, and finally in two other representative market models. The occurrences of historical patterns from Speculation Game suggest that the speculative spirit of the market may be demonstrated as the significant deviation from the uniform frequency patterns. This implication can also be verified from the statistical results of those highly speculative assets, such as gold price and foreign exchange rates. Furthermore, it is found that the reproduction of such historical patterns requires a bottom-up modeling of the markets, as the price change patterns can hardly be achieved in stochastic process models.

### 1 はじめに

金融資産におけるリターンの時系列データには、定型化された事実 (stylized facts) と総称されるいくつかの定性的性質が存在する。たとえば、重要な性質としては、ボラティリティの大きい箇所がまとまって現れる「ボラティリティ・クラスタリング」がよく知られている。Cont の報告 [1] によれば、様々な市場や金融商品において、このボラティリティ・クラスタリングを含めた 11 もの定型化された事実が確認されている。

投機ゲーム [2] は、より多くの定型化された事実の再現、および、それら創発メカニズムのボトムアップ分析を可能にすることを目標に構築した適応型のエージェント・ベース・モデルである。本モデルの最大の特徴は、少数派ゲーム [3] の意思決定構造を応用することで、[4] において指摘された往復取引による売買差益・差損での戦略評価を実現している点である。さらに、価格変動の大きさを認知する仕組みを取り入れ、現実の世界と認知的世界の相互投影を通じて、プレイヤーの意思決定がなされる点も独創的である。このようなユニークな特徴を有する投機ゲームは、比較的シンプルなモデルでありながら、ボラティリティ・クラスタリングを含め (図 1 参照), 11 個中 10 個の定型化された事実

を同一のパラメータ設定下で再現することができる。

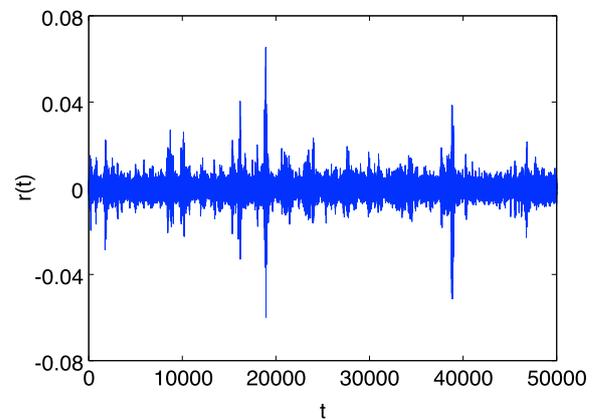


図 1: ボラティリティ・クラスタリングの再現 ( $N = 1000$ ,  $M = 5$ ,  $S = 2$ ,  $B = 9$ ,  $C = 3$ ).

この投機ゲームには、「一般の投機家が、価格チャート等を利用して、過去の値動きから買いや売りのシグナルを見極め、売買差益を狙って注文を行う」様子について、抽象的ながらモデリングされている。このような売買シグナルを通じた投機偏重の注文群によって形成される価格ダイナミクスには、何らかの特徴的痕跡が残るのではないかと考えられる。そこで、本研究では、投機ゲームにおける価格変動のパターン、より具体

\*連絡先: 東京大学大学院新領域創成科学研究科  
〒 277-8563 千葉県柏市柏の葉 5-1-5  
E-mail: k.katahira@scslab.k.u-tokyo.ac.jp

的には、過去の価格変動を離散値で表した履歴パターンについて統計調査を行った。また、これに加え、実際の金融市場からのデータとして、金の価格と米ドル/スイスフランの為替レート、代表的な市場モデルからのデータとして、確率過程モデルのGARCH(Generalized autoregressive conditional heteroscedasticity)モデル[5]やエージェント・ベース・モデルのGCMG(Grand Canonical Minority Game)[6]で生成した価格の時系列に対して、同様の統計調査を行い、比較・検証した。

## 2 投機ゲーム

投機ゲームは、公開型ゲーム市場において、 $S$ 個の戦略をランダムに付与された $N$ 人のプレイヤーが、往復取引を通じて資本を増やそうと互いに競い合う繰り返しゲームである。各時間ステップ $t$ において、プレイヤー $i$ は、最も有益な戦略 $j^*(\in S)$ を用いて、買い(=1)と売り(=-1)と待機(=0)の中から、行動 $a_i^{j^*}(t)$ として1つ選ぶ。注文する場合、注文量 $q_i(t)$ は、保有する資本 $w_i(t)$ に応じて、式1の床関数により決定される。

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

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、往復取引開始時の注文量 $q_i(t_0)$ と終了時の注文量 $q_i(t)$ は、同量とする。また、富の初期値 $w_i(0)$ は、少なくとも1単位は注文できるように、一様分布 $U[0, 100)$ を用いて、

$$w_i(0) = \lfloor B + U[0, 100] \rfloor \quad (2)$$

とする。往復取引の結果、 $w_i(t) < B$ となった場合には、プレイヤーは市場から退出し、式2と同様に決められた資本と $S$ 個の戦略をランダムに付与された代わりの新規プレイヤーが参入する。

市場価格の変動 $\Delta p$ は、Cont and Bouchaud[7]の定義式に倣い、初期価格を $p(0) = 100$ として、

$$\Delta p = p(t) - p(t-1) = \frac{1}{N} \sum_{i=1}^N a_i^{j^*}(t) q_i(t) \quad (3)$$

とする。履歴 $H(t)$ を構成する離散価格変動 $h(t)$ は、 $\Delta p$ と認知閾 $C$ の大小関係により、式4のように決まる。 $C$ は、大きな価格変動とプレイヤーが認識する境界値を表す。

$$h(t) = \begin{cases} 2 \text{ (大きく上昇)} & \text{if } \Delta p > C, \\ 1 \text{ (上昇)} & \text{if } C \geq \Delta p > 0, \\ 0 \text{ (変化なし)} & \text{if } \Delta p = 0, \\ -1 \text{ (下落)} & \text{if } -C \leq \Delta p < 0, \\ -2 \text{ (大きく下落)} & \text{if } \Delta p < -C. \end{cases} \quad (4)$$

行動 $a_i^{j^*}(t)$ を決定するにあたり、記憶長 $M$ のプレイヤーは、過去 $M$ 時間ステップ分の履歴(初期値はランダム)を参照する。そして、確認した履歴パターンに対し、戦略 $j^*$ が推奨する行動をプレイヤーは選ぶ。ただし、往復取引開始時の行動 $a_i^{j^*}(t_0)$ と同じ行動を勧める場合には、待機を選択する。

最も有益な戦略 $j^*$ を見極めるため、バックグラウンドにおいて、未使用戦略による仮定の往復取引も行われる。各戦略のパフォーマンスは、 $H(t)$ における $\Delta p$ の情報の粗さに対応した認知価格 $P(t)$ を通じて計算される累積戦略利得 $G_i^j(t)(j \in S)$ によって評価する。認知価格は、 $P(0) = 0$ として、式5に従って更新される。

$$P(t) = P(t-1) + h(t). \quad (5)$$

ここで、戦略 $j$ による往復取引の利得 $\Delta G_i^j(t)$ は、

$$\Delta G_i^j(t) = a_i^j(t_0)(P(t) - P(t_0)) \quad (6)$$

と計算できるので、累積戦略利得 $G_i^j(t)$ は、

$$G_i^j(t) = G_i^j(t_0) + \Delta G_i^j(t) \quad (7)$$

となる。最も有益な戦略を選出するため、使用戦略による累積戦略利得 $G_i^{j^*}(t)$ が更新される度、プレイヤーは、すべての $G_i^j(t)$ を比較する。その結果、バックグラウンドで取引中の未使用戦略が最も有益な戦略になった場合には、その仮想開始ポジションを直ちに解消し、次の時間ステップから使用する。

往復取引を終えると、プレイヤーの資本 $w_i(t)$ は、注文量 $q_i(t)$ を考慮した戦略利得を任意の関数 $f$ で変換した資本調整 $\Delta w_i(t)$ によって、式8のように更新される。

$$\begin{aligned} w_i(t) &= w_i(t_0) + \Delta w_i(t) \\ &= w_i(t_0) + f(\Delta G_i^{j^*}(t) q_i(t_0)). \end{aligned} \quad (8)$$

投機ゲームでは、モデルの複雑化を避けるため、 $\Delta w_i(t) = \Delta G_i^{j^*}(t) q_i(t_0)$ としており、また、自己金融の仮定も置いていない。なお、以上の投機ゲームの枠組みをまとめると、図2のようになる。本モデルにおける認知的世界の存在は、複雑な情報を簡略化して扱う人間の思考傾向を反映している。

## 3 結果・考察

各パラメータを[2]での基準値( $N = 1000$ ,  $M = 5$ ,  $S = 2$ ,  $B = 9$ ,  $C = 3$ )に設定してシミュレーションを50,000時間ステップ行い、投機ゲームにおける各履歴パターンの出現回数の統計をとった。離散価格変動は5通りの値をとるので、 $M = 5$ のとき、総履歴パター

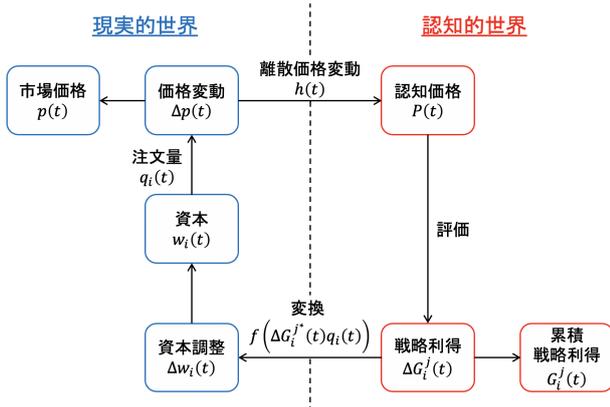


図 2: 現実的世界と認知的世界の相互投影.

ン数は  $5^M = 3,125$  通りある. 図 3 は, 各履歴パターンの出現回数を片対数グラフで示したものである. 特定の履歴パターンばかりが, 多く出現していることが分かる. 履歴の出現パターンが完全ランダムであれば, 分布は一様になるはずであるが, 図 3 の分布は一様になっていない.

さらに, 出現回数の特に多い (50 回以上出現の) 履歴パターンを抽出してみたところ, それらは合計  $2^M = 32$  通りあり, すべて  $-1$  と  $1$  のみで構成されていることが分かった. また, 抽出した履歴パターンのみで出現回数をプロットしてみたところ, 図 4 にあるように, 大きな 2 つの山がある特徴的な分布が得られた. 2 つのピークの履歴は, 順に  $[-1, 1, -1, 1, -1](10)$ ,  $[1, -1, 1, -1, 1](21)$  であり, 共に  $-1$  と  $1$  が交互に並んだパターンである. 逆に, 最も出現回数の少ない履歴は,  $[-1, -1, -1, -1, -1](0)$  と  $[1, 1, 1, 1, 1](31)$  のいずれか一方の数字のみで構成されるパターンである.

このように, 履歴パターンによって出現回数が大きく異なり, 図 4 が判然とした特徴のある分布になるの

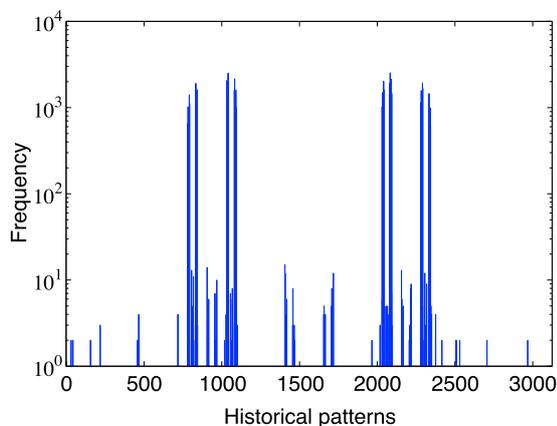


図 3: 全履歴パターンの出現回数の分布.

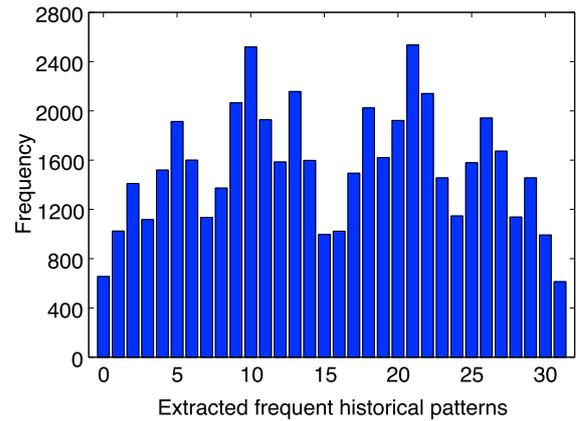


図 4: 抽出した高頻出の履歴パターンの分布.

は, 投機ゲームのプレーヤーが全員投機家であることに起因するのではないかと考えられる. つまり, 市場の投機色が著しく強いために, 各履歴パターンの出現具合にはっきりとした偏りが出ている可能性がある. ならば, 実際の市場においても, 投資色よりも投機色の強い金融商品であれば, その価格には, 同種のシグナルパターンの偏りが潜在するように思われる.

そこで, 一般に投機色が強いと思われるいくつかの金融商品の価格時系列から  $\Delta p$  を計算し, 同様の手法<sup>1</sup>で各履歴パターンの出現回数を調べてみたところ, 一部の商品から履歴パターンの偏りが確認された. 図 5 と図 6 は, それぞれ金の日足インデックス (1978.12.29 - 2018.8.10) と米ドル/スイスフランの日足為替レート (1998.7.30 - 2017.10.2) から算出した履歴パターンから, 図 4 と同様に高頻出のパターンのみ抽出して作成した頻度分布である. 両図からは, 投機ゲームの場合ほど鮮明ではないものの, 履歴パターン間における確かな偏りが認められる. よって, 履歴パターンの偏りは, 投機色の強さの裏付けとなる可能性がある.

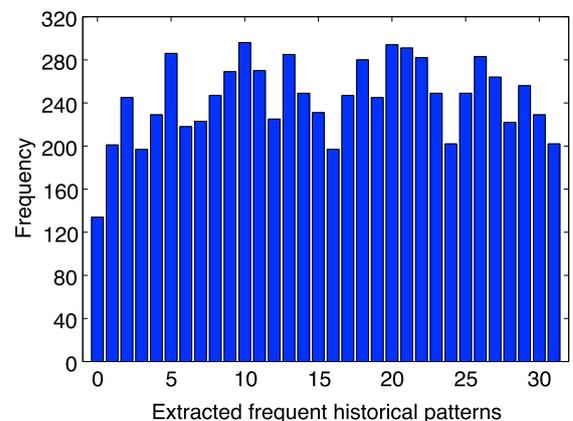


図 5: 金の履歴パターンの分布.

<sup>1</sup>C には,  $\Delta p$  の  $3\sigma$  を用いた.

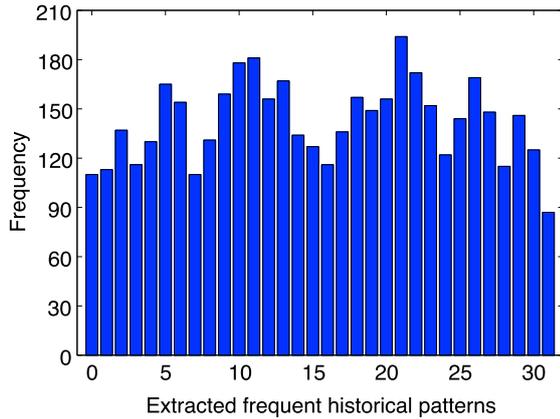


図 6: 米ドル/スイスフランの履歴パターンの分布.

さらに、ボラティリティ・クラスタリングを再現することができる代表的な確率過程モデルの GARCH モデルとエージェント・ベース・モデルの GCMG においても<sup>2</sup>、同種の履歴パターンの偏りが見られるかどうかを調べた。図 7 は、GARCH モデルから生成した定常化後<sup>3</sup>50,000 時間ステップ分のログリターンから価格変動<sup>4</sup>と履歴を求め、高頻出の履歴パターンのみでプロットした頻度分布である。図 7 では、各履歴パターンがほぼ同程度出現しており、大きな頻度の偏りは見られない。一方、GCMG で生成した価格時系列には、履歴パターン<sup>5</sup>に偏りが生じる。図 8 は、定常化後<sup>6</sup>の GCMG のログリターン 50,000 時間ステップ分から図 7 と同様に作成した高頻出の履歴パターンの頻度分布である。図 7 とは違い、履歴パターンによって出現回数が大きく異なっていることが分かる<sup>7</sup>、

このような差異は、両者のモデリングにおける視点の違いに因ると考えられる。GARCH モデルは、出力するリターンと同じマクロレベルで確率を使ってモデリングされている。しかし、GCMG は、ミクロレベルからモデリングされており、エージェントの行動の集積としてリターンが求められる。つまり、GCMG のリターンには、利益を狙う各エージェントの意思が市場のムードとして反映されており、これが、履歴パターンの偏りに繋がっているように思われる<sup>8</sup>。次の値が完全に確率のみで決まる GARCH モデルでは、市場の投機色を表現できていない可能性が高い。

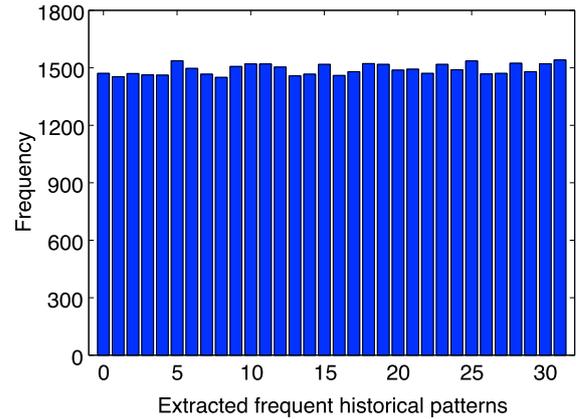


図 7: GARCH モデルの履歴パターンの分布 ( $a_0 = 6.034 \times 10^{-8}$ ,  $a_1 = 5.260 \times 10^{-2}$ ,  $b = 0.9418$ ).

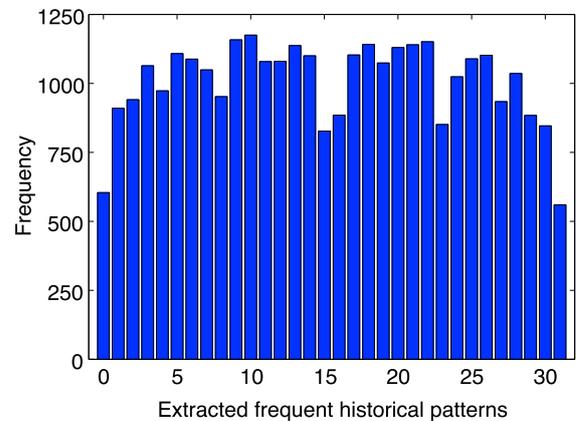


図 8: GCMG の履歴パターンの分布 ( $P = 16$ ,  $S = 2$ ,  $N_s = 501$ ,  $N_p = 1,001$ ,  $\epsilon = 0.01$ ,  $\lambda = N_s + N_p$ ).

## 4 むすび

本研究では、投機ゲームや実際の金融商品、代表的な市場モデルにおける価格変動を、履歴パターンの出現回数という観点から統計調査を行った。その結果、投機ゲームによる分析から、市場の投機色が履歴パターンの出現回数の偏りとして現れる可能性があることが示唆された。この可能性は、金や為替レートといった実際に投機色が強いと思われる金融商品の分析結果も支持している。また、履歴パターンの偏りは、確率過程モデルでの再現は難しく、エージェント・ベース・モデルといったミクロレベルからのモデリングが必要であると考えられる。

なお、本研究を通じて明らかになった履歴パターンの偏りは、新たな定型化された事実と成りうる可能性がある。したがって、より多種多様な金融商品に対し、様々なタイムスケールでこのような統計調査を引き続き行う必要がある。

<sup>2</sup>GARCH モデルと GCMG の詳細は、[5] と [6] を参照。

<sup>3</sup>5,000 時間ステップ後。

<sup>4</sup>初期価格は 100 とした。

<sup>5</sup>ここで言う履歴とは、入力乱数の履歴ではない。

<sup>6</sup>20,000 時間ステップ後。

<sup>7</sup>初期値の乱数によりボラティリティ・クラスタリングが出現しない場合の時系列データを使用すると、履歴パターンの偏りはやや弱くなる。

<sup>8</sup>ただし、偏りは、投機ゲームの場合より弱い。これは、モデルの構造上、投機型エージェント以外も必須であることが要因であろう。

## 謝辞

本研究は、JSPS 科研費 JP17J09156 の助成を受けたものです。

## 参考文献

- [1] R. Cont.: Empirical properties of asset returns: stylized facts and statistical issues, *QUANTITATIVE FINANCE*, Vol. 1, pp. 223–236 (2001)
- [2] K. Katahira., Y. Chen., G. Hashimoto., H. Okuda.: Development of an agent-based speculation game for higher reproducibility of financial stylized facts, *Physica A: Statistical Mechanics and its Applications* (under review)
- [3] D. Challet., Y.-C. Zhang.: Emergence of cooperation and organization in an evolutionary game, *Physica A: Statistical Mechanics and its Applications*, Vol. 246, No. 3, pp. 407–418 (1997)
- [4] 片平啓, 秋山英三: 参加周期の異なるプレイヤーが混在する少数派ゲーム, *情報処理学会論文誌*, Vol. 58, No. 1, pp. 269–277 (2017)
- [5] T. Bollerslev.: Generalized autoregressive conditional heteroskedasticity, *Journal of econometrics*, Vol. 31, No. 3, pp. 307–327 (1986)
- [6] D. Challet, M. Marsili, Y.-C. Zhang.: Stylized facts of financial markets and market crashes in minority games, *Physica A: Statistical Mechanics and its Applications*, Vol. 294, No. 3, pp. 514–524 (2001)
- [7] R. Cont., J.-P. Bouchaud.: Herd behavior and aggregate fluctuations in financial markets, *Macroeconomic dynamics*, Vol. 4, No. 2, pp. 170–196 (2000)

# 板の中心値段からの距離と約定の関連分析

## Analysis of high-frequency trading from the viewpoint of tick distance and Execution

幸田 茂樹<sup>1</sup> 吉田 健一<sup>1</sup>

Shigeki KOHDA<sup>1</sup>, Kenichi YOSHIDA<sup>1</sup>

<sup>1</sup> 筑波大学大学院システム情報工学研究科

<sup>1</sup> University of Tsukuba Graduate School of Systems and Information Engineering

**Abstract:** The increase of high-frequency trading (HFT) in stock market increases the importance of the analysis of its behaviors. In this study, we analyze it based on the previous research which analyzed it from the viewpoint of “Make and Take orders”. The characteristics of our analysis is “analysis of tick distance”, and our findings include: 1) the upgrade of stock trading system enables the handling of current trading volume that increased 4 times from 2010 to 2018, 2) Although HFT is making “make orders” away from the best quotes, such orders will not be executed.

### 1. はじめに

東京証券取引所の現物株の取引高は世界でも有数であり、国内でも大きなシェアを占めている。またマーケットの状況は、海外投資家のシェアが 2006 年に 30% だったものが、2013 年には 60% を超えるなど、大きく変化している。同時期にはアルゴリズム取引の数が急速に伸びている。図 1 では、アベノミクスの影響や活発なアルゴリズム取引によって、一日の注文件数が平均 4000 万件に増加した。また高速な取引を行う際のコロケーションサービスを利用した注文比率が 7 割を超え、HFT（高頻度取引）が市場での重要性が増した。

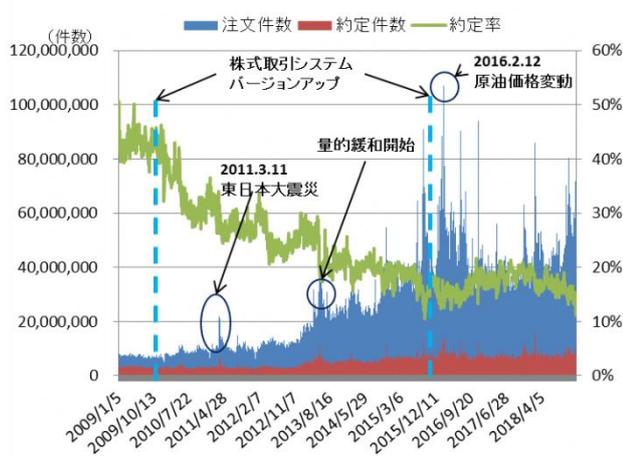


図 1 注文・約定件数と約定率

このような HFT の特性を分析しようとする研究は多い。Ferber[1]は 1) コロケーションを利用し、2) 一日を通した約定代金がポートフォリオの 50% 以上で、3) 注文執行比率が 25% 未満、4) 取消注文比率が 20% 以上、5) 半分以上の株を当日中に売却し、6) 50% 以上の株式売買においてリベートを受領している、の 6 条件のうち最低 4 つの条件に当てはまる取引主体を HFT と定義している。

HFT の取引手法としては、1) マクロニュースに即座に反応すること、2) 市場の幅広い値動きに反応すること、3) 板情報の指値注文の差を評価して注文を出すこと、が報告されている (Brogaard[2])。一方市場に対する影響としては、Hasbrouck [3]が 1) 株式市場の短期間におけるボラティリティを低下させ価格変動を抑制する働きがあることや、2) スプレッドの減少によって取引機会の向上が図られることを報告している。

保坂[4]は Ferber[1]の定義にならない注文執行比率が 25% 未満かつ取り消し注文比率が 20% 以上であるサーバを HFT として、東京証券取引所における HFT の取引が価格形成と流動性に対してどのような影響を与えるのか分析した。その結果、1) 立会時間中、HFT による注文件数は HFT 以外の注文件数より多く、2) 即座に約定するテイク注文の約定件数は、即座に約定しないメイク注文による約定件数と比較して少なく、3) メイク注文による約定が多いことから市場に流動性を提供している事を示した。Yoshida[5]は、HFT の挙動を分析し、ミリ秒の短時間での株価

について確率的に一定した方向性があることを示した。

2010年1月と2015年9月には株式売買システムが更新され、その都度注文約定の速度アップが図られ、市場の環境が変化した。本研究では、このようなシステムの更新が市場に与えた影響を分析し、保坂[4]やYoshida[5]の研究結果がシステム更新後の現在でも変わらずになりたっているかを再確認する。また、従来の研究では十分に分析されていなかった板の中心値段からの距離と約定の関係について詳細な分析を試みる。

## 2. 板の中心値段から呼値単位の距離

### 2.1. 株式売買システムの更新

東証の株式売買システムは2015年にアップグレードされ、注文の応答時間は0.5ミリ秒未満に、また情報配信時間は1.0ミリ秒未満になり、前のシステムの倍以上の性能となった。このアップグレードによりシステムが高速になったことが一因で、よりHFTが取引を行う環境が整い、取引量が増加した。

本研究では、保坂[4]が行った旧システム稼働時の分析を現在のシステム環境下の取引データを用いることで再分析することにより、どのように変化したのか分析を試す。研究の前提は保坂[4]に従う。比較のため、2010年8月、2013年5月、2018年5月の取引を対象とした。使用したデータは板再現データと呼ばれ、取引参加者の情報を含むため一般には公開されていないが守秘義務を負った上で東証から提供を受けた。広く公開されているFlexデータは取引参加者の注文情報はないが、板再現データは注文時間、注文価格、注文数量、注文条件、約定時間、約定価格、約定数量そして取引参加者（仮想サーバ）などの詳細な情報が含まれている。

本研究では保坂[4]の使用した2013年5月のデータと比較するために2018年5月の板再現データを使用し、また新たな観点で分析するために、2010年8月31日、2013年5月31日のデータを使用した(2010年、2013年のデータの取得方法が特殊であり、大量に情報を得ることが時間的な制約で難しかった為1日分のみ用いた)。注文の発注は、仮想サーバ単位で区分できる。基本的に取引参加者は複数の仮想サーバを登録しており、取引参加者の先にいる顧客ごとに仮想サーバを振り分けている。時に、複数の顧客が同一の仮想サーバを使用する場合があるが、本研究では、仮想サーバ単位でHFTかどうかを既存研究の定義に従い判別した。

図2は、HFTの最小の発注単位である仮想サーバ

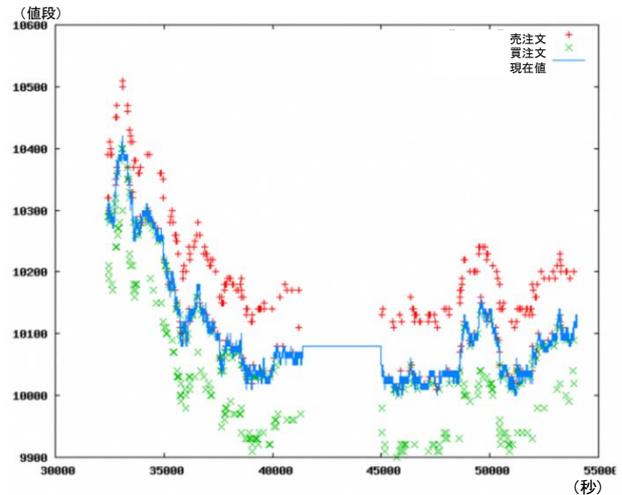


図2 現在値と売買の注文

からの現在値、売注文、買注文を示した図である。HFTサーバの定義についてはFerber[1]に従っている。あくまで一例だが、HFTが現在の値に近い箇所(青)と一定間隔をあけた箇所(赤と緑)で注文を出していることが分かる。後述したとおり約定は板の中心の値段近傍を中心に行われている事が分かったことから、次章以降では板の中心となる価格から注文値段を最小に細かく指定できる呼値単位での分析を行った。

### 2.2. 2013年5月と2018年5月の比較

初めに保坂[4]が分析した2013年5月のデータと新しく2018年5月のデータを用いて特徴を比較する。2013年5月のデータとHFTの定義は保坂[4]から引用した。

- 新規上場した銘柄、上場廃止された銘柄、市場区分が変更された銘柄は除外
- 1ヶ月の各日においてHFTによる約定金額が5000万円未満の日がある銘柄も除外

表1の条件を満たした銘柄数は減少した。アベノミクスの最中であることから市場が活況であることが推測されるが、HFTの対象株式数は減少した。これは、HFTの市場での特性の変化を示唆した。表2以降の集計は本対象の銘柄の元にする。

表1 対象銘柄数

	2013年5月	2018年5月
東証一部銘柄総数	1,713	2,329
対象銘柄数	373	218
割合	21.8%	9.4%

表 2 総注文件数と総約定件数

		2013年5月	2018年5月
総注文件数	全体	34,462,663	275,918,068
	HFT	18,962,752	41,030,039
	HFTの比率	55.0%	14.9%
総約定件数	全体	10,167,580	57,302,810
	HFT	3,668,390	4,245,442
	HFTの比率	36.1%	7.4%
約定率	全体	29.5%	20.8%
	HFT	19.3%	10.3%
	HFTの比率	41.9%	22.6%

表 3 総注文金額と総約定金額

		2013年5月	2018年5月
総注文金額 (10億円)	全体	61,651	139,581
	HFT	31,813	17,965
	HFTの比率	51.6%	12.9%
総約定金額	全体	16,455	30,419
	HFT	4,254	2,027
	HFTの比率	25.9%	6.7%
約定金額比率	全体	26.7%	21.8%
	HFT	13.4%	11.3%
	HFTの比率	40.9%	23.3%

表 4 注文タイプ別の注文金額と比率 (2018年5月)

注文タイプ	注文金額(単位:10億円)			各注文の比率		
	合計	HFT	非HFT	合計	HFT	非HFT
a 立会時間外	25,076	3,536	21,540	13.0%	15.1%	12.7%
b 成行注文	8,736	215	8,521	4.5%	0.9%	5.0%
c 即時約定指値注文	22,016	1,662	20,353	11.4%	7.1%	12.0%
d 最良執行値段更新指値注文	13,657	1,364	12,293	7.1%	5.8%	7.3%
e 最良執行値段指値注文	38,436	6,365	32,071	19.9%	27.1%	18.9%
f 最良執行値段外指値注文	68,034	8,773	59,260	35.3%	37.3%	35.0%
g 引け条件付注文	16,869	1,579	15,290	8.7%	6.7%	9.0%

表 5 注文タイプ別の注文金額と比率 (2013年5月)

注文タイプ	注文金額(単位:10億円)			各注文の比率		
	合計	HFT	非HFT	合計	HFT	非HFT
a 立会時間外	3,116	221	2,895	5.0%	0.7%	9.5%
b 成行注文	1,209	113	1,097	1.9%	0.3%	3.6%
c 即時約定指値注文	7,624	1,615	6,008	12.2%	5.0%	19.8%
d 最良執行値段更新指値注文	2,264	1,237	1,027	3.6%	3.8%	3.4%
e 最良執行値段指値注文	10,713	5,493	5,221	17.1%	17.0%	17.2%
f 最良執行値段外指値注文	31,989	22,980	9,009	51.0%	71.1%	29.6%
g 引け条件付注文	5,796	650	5,146	9.2%	2.0%	16.9%

表 2 は、対象の銘柄における 2013 年 5 月と 2018 年 5 月の注文件数と約定件数を比較した表である。表が示すように、注文件数は増加したが、HFT の比率は低下した。同様に HFT の約定件数も増加したが比率は低下した。約定率は HFT と非 HFT 共に低下した。

表 3 は注文金額と約定金額を比較した表である。表が示すように、全体の総注文・総約定金額は増加しているが、HFT の総注文・総約定金額の比率は低下した。また HFT の約定金額比率が低下した。

表 4 表 5 は 2013 年 5 月と 2018 年 5 月、注文タイプ別の注文金額を示している。タイプ b およびタイプ c は、即座に約定するテイク注文で、タイプ d、e、およびタイプ f は、即時に約定しないメイク注文である。タイプ a の立会時間時間外の注文であり、タイプ b は成行注文で即座に約定する。タイプ c は指値注文で即座に約定する。タイプ d は立会中に即座

に約定することなく、売注文であれば最も安い値段、買注文であれば最も高い注文値段（最良執行値段）を更新する注文である。タイプ e は、最良執行値段と同値の注文である。タイプ f は最良執行値段以外で即座に約定しない指値注文である。タイプ g は引け条件付注文などの条件が付いた注文である。

表 4 と表 5 が示すように、タイプ f の HFT の注文金額は減少し、他のタイプの HFT の注文金額は増加した。非 HFT は、すべての注文タイプで注文金額が増加した。また、表 6 が示すように 2013 年 5 月と 2018 年 5 月ともに、HFT のメイク注文の比率がテイク注文数を上回った。2013 年 5 月の HFT のテイク注文の比率と比べ 2018 年 5 月の同比率は上昇した。HFT はメイク注文に比べてテイク注文の活用比率を増やしたことが分かる。メイク・テイク注文は市場の流動性と密接に関係している。2018 年においても HFT のメイク比率が非 HFT に比べて高いことから、

表 6 テイク・メイク注文件数の比

	2013年5月		2018年5月	
	HFT	非HFT	HFT	非HFT
テイク注文	5.50%	31.77%	10.21%	21.79%
メイク注文	94.50%	68.23%	89.79%	78.21%

HFT は市場の流動性提供に寄与していると分かり、依然としてマーケットメーカーの役割を果たしている。ただ、テイク注文の比率が上昇したことから、テイク注文で売買を増やすよう注文特性が変わった可能性がある。

2013年5月と2018年5月を比較すると、東証一部の銘柄総数は増加しているが、対象銘柄数は低下した。HFTの注文総数と約定総数は増加したが、総注文金額と総約定金額は減少した。また注文タイプ別の検証から、HFTタイプfの総注文金額のみが減少したため、HFTに関して板の中心から離れた注文金額が減少した。つまり、板の中心に近いところに注文における金額を割り振るようになった。この板の中心付近の売買特性が市場の特徴であると考え、次の章で最良執行気配における金額だけでなく、注文件数と約定件数を紐付けて検証した。

### 2.3.最良執行値段を用いた分析

本章では、前章で保坂[4]が実施した注文における最良執行値段(立会中、板上の最も高い買注文値段、最も低い売注文値段)を軸とした分析に加え、テイク・メイク注文のtick(証券毎に決まる売買価格の最小単位、呼値)毎の分布を調べる。

データは2010年8月31日、2013年5月31日、2018年5月31日と2.2章で使用した2018年5月の一か月分を用いた。2010年8月31日、2013年5月31日の過去分は直近分(2018年5月、2018年5月31日)との比較目的であり、2018年5月の1ヶ月は2.2章の解析を詳細に見るためかつ他の期間との比較目的である。また、HFTと非HFTについても比較する。

HFTの定義は前章の通り、注文執行比率25%未満かつ取消注文比率が20%以上である仮想サーバとした。銘柄については、HFTは注文が多く入る銘柄に特に注文を入れると言われているため2010年8月31日、2013年5月31日、2018年5月31日の各日で注文総件数の上位1-100位、201-300位の銘柄で分析した。また、2018年5月の一ヶ月分では、前章で定義した銘柄(表1参照)を対象として分析した。

表7-12に、売り買いに分かれた注文件数・金額比率、テイク注文件数・金額比率、メイク注文件数・金額比率を最良執行値段からの呼値単位で分類した結果を示す。前述の通り、呼値とは株を注文する際の価格の刻み幅のことを意味しtickとも表記する。

株価によって、0.1円刻み、1円刻み、100円刻みなどがある。TOPIX100銘柄は特別な呼値の一覧があり、本研究では計算の条件に入れて分析した。また、8tick以上、8tick以下は合算値とした。分析の結果:

- 表7は3時点のHFTが注文した1-100銘柄分の表である。メイク注文は0tickの約定とテイク注文の±1tickの約定の比率が最も大きいことから、大部分の約定は±1tick以内の注文で行われる。また、3時点の注文件数比率を比較すると、0tickの比率がもっとも大きかった。時間を経る毎に比率は増加し、また2010年8月31日から2013年5月31日にかけて2番目に比率が大きい箇所は±4tickから±1tickの箇所に変化し、注文が0tick近傍に集中する様に変化した。テイク注文に関して、2010年8月31日、2013年5月31日は売件数・金額は-1tickがもっとも比率が多く、2番目は-2tick、3番目は-5tickであり、買側は対称的だった。一方2018年5月31日は±5tickの集中がなくなり、0tick以外に比率の大きな集中はなくなった。

このため時間を経るごとにHFTによるテイク注文の約定が±1tick近傍で行われるように変化した。

- 表8は3時点のHFTが注文した201-300銘柄分の表である。2010年8月31日の売側+1tickと+3tickの注文金額比率は13.4%と12.9%で0.5%差であるが、注文件数は16.4%と7.7%で8.7%差があった。+3tickで金額の比率が大きくなっていることから1件あたりの注文の株数が多くなっていることが分かった。また、2013年5月31日の買注文金額の一番比率が大きいのは、0tickではなく-2tickであった。-2tickに金額比率のピークがあることから-2tickにおける1件あたりの注文の株数が他のtickと比べて大きいことが分かる。HFTの上位100銘柄(表7)においても2010年8月31日と2013年5月31日で同様の傾向が見られた。

このような件数比率と金額比率を比較して特定のtickに株数が多い状態は、全取引参加者にとって注文元の仮想サーバや取引参加者が分らず、大量の注文があるように見える。2tick以上離れた注文は株数の大きな注文となる傾向があった。しかし、2018年5月31日のデータにはその特徴は見られなかった。

- 表9は3時点の非HFTが注文した1-100銘柄分の表である。3時点の注文件数を比較すると、HFTの上位1-100銘柄における0tickの注文件数比率は時間を経る毎に増加したが(表7)、非HFTの売側は減少し、買側は増加した。

同様にテイク注文に関して、売注文件数・金額比率は-1tick がもっとも多く、2番目は-2tick であるが、3番目は-5tick となった。買注文件数・金額比率は、対称的だった。2010年8月31日、2013年5月31日はHFTと同様にテイク注文は離れた tick 数の箇所での約定件数と金額が多いが、2018年5月31日は表7と同様に0tick 近傍の約定が集中した。

- 表10は3時点の非HFTが注文した201-300銘柄の表である。2013年5月31日のテイク注文に関しては、表7-9と同様に売注文件数・金額は-1tick がもっとも比率が多く、2番目は-2tick であるが、3番目は-5tick となった。買注文は対称的だった。2013年5月31日から2018年5月31日にかけて、テイク注文の件数の±5tick の集中がなくなっていることから、テイク注文特徴が変化したことがわかる。
- 表11は2018年5月におけるHFTが表1対象銘柄の注文の集計表である。売買側ともに注文件数・金額比率、メイク注文件数・金額比率は±0tick が最も大きい。テイク注文件数・金額比率は売側は-1tick、買側は+1tick が最も大きい。
- 表12は2018年5月における非HFTが注文した表1の対象銘柄に係る集計表である。

### 3. 結論

本研究ではアルゴリズム取引、特にHFTの重要性を考慮し、特に板の中心値段からの距離と約定の観点からその特性を分析した。結果は以下のようにまとめられる。

- ✓ 2015年のシステムアップグレードにより、発注可能件数の増加や約定数の増加により耐えられるようになった。またアップグレード後の新株式売買システムやアベノミクスの影響により取引方法の変更が確認できた。
- ✓ 注文の大部分の約定は±1tick 以内の注文で行われる。時間を経るごとにHFTによるテイク注文の約定が±1tick 近傍で行われるように変化した。
- ✓ 2010年8月31日と2013年5月31日において、2tick 以上離れた注文は株数の大きな注文となる傾向があった。
- ✓ これまでの研究と比較して、2018年におけるHFTの注文数は増加しているが、対象の銘柄数と金額は減少した。また注文および金額におけるHFTの比率も減少した。
- ✓ HFTは依然としてマーケットメーカーの役割

を果たしている。2018年5月でも、HFTのメイク注文数はテイク注文数よりも多いが、メイク注文の比率は低下しテイク注文の活用比率を増やした。

- ✓ HFTの上位1-100銘柄における0tickの注文件数比率は時間を経る毎に増加したが、非HFTの売側は減少し、買側は増加した。

### 4. 今後の課題

0tick、±1tickの注文・約定件数と金額が他のtickより多く、近傍での価格分析の重要性を示している。Yoshida[5]の研究では板の中心値段から何tick離れているかの検討は行っていない。本分析結果からは、その情報を入れる事による価格予測精度の向上が予想され、実際に確認する事が今後の課題である。

### 参考文献

- [1] Ferber M.: on the proposal for a directive of the European Parliament and of the Council on markets in financial instruments repealing Directive 2004/39/EC of the European Parliament and of the Council (recast), EUROPEANPARLIAMENT, [http://www.europarl.europa.eu/sides/getDoc.do?type=REPORT&reference=A7-2012-0306&language=EN#title1,\(2012\)](http://www.europarl.europa.eu/sides/getDoc.do?type=REPORT&reference=A7-2012-0306&language=EN#title1,(2012))
- [2] Brogaard J., Hendershott T. and Riordan R., :High Frequency Trading and Price Discovery, EUROPIAN CENTRAL BANK working paper series No. 1602
- [3] Hasbrouck J. and Saar G. :Low-latency trading, Journal of Financial Markets 16 pp. 646-679,(2013)
- [4] 保坂 豪: 東京証券取引所における High-Frequency Trading の分析, JPX working paper, Vol. 4, (2014)
- [5] Yoshida K. and Sakurai A.: Short-term Stock Price Analysis Based on Order Book Information, Transactions of the Japanese Society for Artificial Intelligence, Vol. 30, Issue5, (2015)

①: 2010年8月31日  
②: 2013年5月31日  
③: 2018年5月31日  
※表7-10共通

表 7 呼値単位の注文・約定の件数と金額 (HFT、1-100 位銘柄)

Table with columns for 'Sell' (売) and 'Buy' (買) orders, categorized by 'Amount' (金額) and 'Quantity' (件数). It includes sub-columns for 'Order Type' (メイク/テイク) and 'Order Type' (テイク/メイク). The table contains 30 rows of data for various order types and time intervals.

表 8 呼値単位の注文・約定の件数と金額 (HFT、201-300 位銘柄)

Table with columns for 'Sell' (売) and 'Buy' (買) orders, categorized by 'Amount' (金額) and 'Quantity' (件数). It includes sub-columns for 'Order Type' (メイク/テイク) and 'Order Type' (テイク/メイク). The table contains 30 rows of data for various order types and time intervals.

表 9 呼値単位の注文・約定の件数と金額 (非 HFT、1-100 位銘柄)

Table with columns for 'Sell' (売) and 'Buy' (買) orders, categorized by 'Amount' (金額) and 'Quantity' (件数). It includes sub-columns for 'Order Type' (メイク/テイク) and 'Order Type' (テイク/メイク). The table contains 30 rows of data for various order types and time intervals.

表 10 呼値単位の注文・約定の件数と金額 (非 HFT、201-300 位銘柄)

売												買																											
約定						注文						注文						約定																					
金額			件数			金額			件数			金額			件数			金額			件数																		
メイク	テイク		メイク	テイク		メイク	テイク		メイク	テイク		メイク	テイク		メイク	テイク		メイク	テイク		メイク	テイク																	
(1)	(2)	(3)	(1)	(2)	(3)	(1)	(2)	(3)	(1)	(2)	(3)	(1)	(2)	(3)	(1)	(2)	(3)	(1)	(2)	(3)	(1)	(2)	(3)																
0.0%	4.2%	0.6%	-	-	-	0.0%	3.0%	0.9%	0.0%	0.0%	0.0%	8.3%	10.3%	17.9%	6.5%	10.0%	9.3%	+8tick以上	0.5%	0.9%	0.6%	0.5%	0.9%	3.7%	2.4%	5.6%	1.9%	-	-	-	2.8%	7.4%	2.2%	-	-	-			
0.0%	0.1%	0.0%	-	-	-	0.0%	0.2%	0.0%	0.0%	0.0%	0.0%	1.3%	0.9%	4.9%	1.0%	0.8%	2.5%	+7tick	0.0%	0.1%	0.0%	0.1%	0.0%	0.2%	0.3%	0.8%	0.3%	-	-	-	0.1%	0.4%	0.4%	-	-	-			
0.0%	0.2%	0.0%	-	-	-	0.0%	0.2%	0.0%	0.0%	0.0%	0.0%	2.1%	1.4%	5.5%	1.7%	1.0%	2.6%	+6tick	0.1%	0.3%	0.1%	0.1%	0.1%	0.2%	0.5%	1.6%	0.6%	-	-	-	0.3%	1.2%	0.7%	-	-	-			
0.0%	0.3%	0.1%	-	-	-	0.0%	0.3%	0.1%	0.0%	0.0%	0.0%	3.0%	2.2%	7.5%	2.2%	1.9%	4.4%	+5tick	0.2%	0.8%	0.2%	0.2%	0.4%	0.2%	1.3%	4.3%	1.1%	-	-	-	0.7%	4.2%	1.4%	-	-	-			
0.1%	0.3%	0.1%	-	-	-	0.1%	0.3%	0.1%	0.0%	0.0%	0.0%	5.8%	2.9%	9.8%	3.7%	3.4%	5.6%	+4tick	0.5%	0.7%	0.2%	0.4%	0.3%	0.2%	2.7%	4.2%	1.3%	-	-	-	2.2%	2.8%	1.6%	-	-	-			
0.2%	1.0%	0.3%	-	-	-	0.2%	0.6%	0.3%	0.0%	0.0%	0.0%	11.3%	5.0%	10.3%	4.3%	3.2%	6.4%	+3tick	0.9%	1.2%	0.5%	0.4%	0.4%	0.7%	4.7%	6.7%	3.5%	-	-	-	1.9%	3.4%	3.2%	-	-	-			
0.8%	1.5%	0.6%	-	-	-	0.4%	1.0%	0.5%	0.0%	0.0%	0.0%	8.4%	15.6%	8.0%	7.2%	6.5%	7.6%	+2tick	2.6%	2.9%	1.8%	1.7%	1.0%	1.2%	13.0%	15.5%	13.5%	-	-	-	10.2%	11.2%	10.0%	-	-	-			
1.5%	3.5%	1.9%	-	-	-	1.5%	3.1%	1.8%	0.0%	0.0%	0.0%	13.1%	9.8%	7.4%	13.8%	12.4%	12.5%	+1tick	16.9%	14.9%	14.5%	13.1%	19.9%	10.6%	75.1%	61.3%	77.7%	-	-	-	92.1%	87.1%	96.1%	-	-	-			
97.5%	88.6%	96.2%	-	-	-	97.9%	91.4%	96.9%	0.0%	0.0%	0.0%	30.9%	32.7%	14.5%	40.9%	41.4%	33.4%	0tick	32.8%	36.9%	33.0%	23.0%	25.0%	16.7%	-	-	-	-	-	-	94.1%	87.1%	96.1%	-	-	-			
-	-	-	-	-	-	-	-	-	-	-	-	80.4%	80.8%	77.0%	12.4%	14.5%	7.8%	14.0%	12.6%	12.2%	-1tick	12.0%	11.7%	11.7%	15.2%	20.7%	9.2%	-	-	-	-	-	-	90.1%	87.6%	95.2%	-	-	-
-	-	-	-	-	-	-	-	-	-	-	-	14.8%	13.6%	1.4%	1.3%	0.9%	2.1%	2.4%	1.5%	-2tick	8.1%	6.3%	8.1%	8.6%	15.0%	8.2%	-	-	-	-	-	-	1.1%	1.0%	1.0%	-	-	-	
-	-	-	-	-	-	-	-	-	-	-	-	3.5%	6.2%	4.2%	0.4%	0.5%	0.4%	0.6%	1.0%	0.5%	-3tick	5.2%	3.3%	6.9%	9.7%	2.6%	10.5%	-	-	-	-	-	0.6%	0.8%	0.4%	-	-	-	
-	-	-	-	-	-	-	-	-	-	-	-	3.8%	1.7%	0.2%	0.3%	0.3%	0.6%	0.2%	-4tick	4.4%	3.9%	5.7%	9.3%	2.4%	9.6%	-	-	-	-	-	0.3%	0.5%	0.2%	-	-	-			
-	-	-	-	-	-	-	-	-	-	-	-	4.0%	0.8%	0.1%	0.5%	0.2%	0.2%	0.6%	0.1%	-5tick	2.7%	2.1%	4.4%	3.1%	1.7%	6.3%	-	-	-	-	-	0.3%	0.4%	0.1%	-	-	-		
-	-	-	-	-	-	-	-	-	-	-	-	0.4%	1.5%	0.4%	0.0%	0.1%	0.1%	0.2%	0.1%	-6tick	2.1%	1.3%	2.4%	2.2%	1.6%	4.1%	-	-	-	-	-	0.1%	0.2%	0.1%	-	-	-		
-	-	-	-	-	-	-	-	-	-	-	-	0.2%	0.9%	0.3%	0.0%	0.1%	0.1%	0.0%	-7tick	1.2%	0.9%	1.9%	1.6%	0.7%	3.2%	-	-	-	-	-	0.1%	0.1%	0.0%	-	-	-			
-	-	-	-	-	-	-	-	-	-	-	-	2.2%	8.1%	2.0%	1.1%	1.9%	4.6%	1.4%	1.8%	1.2%	-8tick以下	8.8%	11.8%	8.0%	10.9%	7.2%	17.1%	-	-	-	-	-	1.4%	6.1%	0.0%	-	-	-	

表 11 呼値単位の注文・約定の件数と金額 (2018年5月、HFT、対象銘柄表1参照)

売						買						
約定			注文			注文			約定			
金額	件数		金額	件数		金額	件数		金額	件数		
メイク	テイク		メイク	テイク		メイク	テイク		メイク	テイク		
3.0%	-	2.8%	-	13.4%	11.8%	+8tick以上	0.4%	2.5%	2.2%	-	1.4%	-
0.3%	-	0.2%	-	2.6%	2.4%	+7tick	0.0%	0.1%	0.3%	-	0.3%	-
0.4%	-	0.2%	-	2.2%	1.5%	+6tick	0.0%	0.1%	0.3%	-	0.3%	-
0.6%	-	0.5%	-	4.5%	4.4%	+5tick	0.1%	0.1%	0.7%	-	0.7%	-
0.7%	-	0.6%	-	4.7%	4.9%	+4tick	0.1%	0.1%	1.2%	-	1.1%	-
1.1%	-	1.0%	-	5.8%	6.2%	+3tick	0.3%	0.3%	3.8%	-	3.0%	-
2.2%	-	2.2%	-	7.2%	10.3%	+2tick	1.9%	1.3%	20.6%	-	14.2%	-
5.1%	-	3.9%	-	12.5%	14.3%	+1tick	7.9%	10.3%	70.9%	-	78.9%	-
86.6%	-	88.5%	-	32.6%	35.6%	0tick	35.2%	35.9%	-	87.9%	-	87.1%
-	78.5%	-	71.7%	6.2%	6.2%	-1tick	13.3%	11.5%	-	4.6%	-	5.7%
-	14.5%	-	20.4%	0.9%	1.3%	-2tick	9.8%	7.2%	-	2.7%	-	2.5%
-	3.2%	-	3.5%	0.3%	0.2%	-3tick	6.3%	5.7%	-	1.2%	-	1.2%
-	1.1%	-	1.0%	0.1%	0.1%	-4tick	5.0%	4.5%	-	0.7%	-	0.7%
-	0.5%	-	0.4%	0.1%	0.0%	-5tick	4.4%	4.3%	-	0.4%	-	0.5%
-	0.2%	-	0.3%	0.1%	0.0%	-6tick	1.6%	2.0%	-	0.3%	-	0.3%
-	0.2%	-	0.2%	0.2%	0.0%	-7tick	2.3%	2.2%	-	0.2%	-	0.3%
-	1.6%	-	2.4%	4.8%	0.7%	-8tick以下	11.2%	11.9%	-	2.1%	-	1.8%

表 12 呼値単位の注文・約定の件数と金額 (2018年5月、非 HFT、対象銘柄表1参照)

売						買						
約定			注文			注文			約定			
金額	件数		金額	件数		金額	件数		金額	件数		
メイク	テイク		メイク	テイク		メイク	テイク		メイク	テイク		
3.7%	-	3.2%	-	18.8%	12.0%	+8tick以上	0.6%	2.3%	2.7%	-	3.2%	-
0.3%	-	0.2%	-	2.8%	2.1%	+7tick	0.1%	0.1%	0.5%	-	0.4%	-
0.4%	-	0.2%	-	3.0%	2.0%	+6tick	0.1%	0.1%	0.5%	-	0.6%	-
0.5%	-	0.4%	-	4.2%	3.1%	+5tick	0.2%	0.2%	1.1%	-	1.1%	-
0.8%	-	0.5%	-	5.7%	4.8%	+4tick	0.3%	0.4%	2.1%	-	2.1%	-
0.8%	-	0.7%	-	6.0%	5.1%	+3tick	0.8%	1.0%	5.5%	-	5.0%	-
1.4%	-	1.2%	-	5.5%	7.5%	+2tick	3.2%	3.4%	19.8%	-	17.3%	-
3.4%	-	2.5%	-	7.1%	12.6%	+1tick	13.2%	18.5%	67.7%	-	70.2%	-
88.9%	-	91.1%	-	25.4%	35.7%	0tick	33.9%	24.2%	-	91.0%	-	89.9%
-	70.5%	-	68.6%	14.0%	10.7%	-1tick	11.7%	7.0%	-	2.9%	-	3.7%
-	17.0%	-	19.5%	2.6%	2.5%	-2tick	7.3%	5.6%	-	1.5%	-	1.6%
-	5.1%	-	5.3%	0.8%	0.6%	-3tick	5.1%	5.5%	-	0.8%	-	0.8%
-	2.1%	-	1.9%	0.4%	0.2%	-4tick	4.8%	5.3%	-	0.5%	-	0.5%
-	1.1%	-	0.9%	0.2%	0.1%	-5tick	3.1%	3.8%	-	0.4%	-	0.4%
-	0.6%	-	0.5%	0.1%	0.0%	-6tick	2.0%	2.6%	-	0.3%	-	0.3%
-	0.4%	-	0.4%	0.1%	0.0%	-7tick	2.1%	2.7%	-	0.2%	-	0.3%
-	3.3%	-	2.9%	3.2%	0.9%	-8tick以下	11.6%	17.2%	-	2.5%	-	2.4%

# イナゴタワーから分かる投資家行動 ~VPIN を用いた仕手株の分析~ Investor Behavior Estimated from Locust Tower

吉川 満<sup>1</sup>

Mitsuru Kikkawa<sup>1</sup>

<sup>1</sup> 大和大学 政治経済学部

<sup>1</sup> The Faculty of Political Science and Economics, Yamato University

**Abstract:** This paper investigates the stock of Terilogy Co., Ltd.(code 3356, JASDAQ) using VPIN (Volume-Synchronized Probability of Informed Trading) proposed in Easley, et al. [1]. Especially, the stock is attracting attention in SNS etc., stock price is fluctuating. We examine the investor behavior with VPIN, and also consider how to use this theory is applied to the stock trading.

## 1 はじめに

仕手株とは、一般的には、「仕手」または「仕手筋」と呼ばれる多額の資金を持った特定の投資家が、短期間に大きな利益を得ることを目的に流動性の低い特定の銘柄に対して大量の買いや売りを入れることにより、株の取引が活発に行われているかのように演じて、一般投資家を誘い込み株価の急騰・急落が起きやすくなっている株のことを指す([2])。

特に近年では、株取引のための情報ツールとしてソーシャルメディアが一般投資家にも浸透している。「カリスマ」と称される著名な投資家には、多くのフォロワーが付き、投稿・つぶやきが個別銘柄の株価を動かすケースもあり、この特定の情報を得た投資家が、一斉に特定銘柄の回転売買を短期で繰り返すことで、株価が急騰・急落を引き起こすことがある<sup>1</sup>。このような取引に参加する個人投資家たちの、突然、現れて利益を得た後は、すぐ別の銘柄に当たるといふ投資行動を、「秋になると一斉に繁殖し大群で飛んできて、稲穂に群がり食い尽くし飛び去るイナゴ」に例えて、「イナゴ投資家」などと呼ばれ、これにより短期売買によって作り出されたチャート形状は「イナゴタワー」と呼ばれる([3])。

このようにイナゴタワーができるようになって

た背景として、ソーシャルメディアの浸透に加え、2013年1月の信用取引の規制緩和に続き、同年11月には空売りの規制緩和が実施されたことや、2014年4月に東証の主力株の値刻みが縮小され、2018年10月には、株式の単位元が100株に統一されたことなどから投資家の利便性が高まり、短期で回転売買を行う投資家が増加する一因となったとも指摘されている。

本稿では、株価が乱高下している株式の取引に関して、私的情報を持っている情報投資家が事前に購入し、その後、大量保有報告書やTwitter等の情報が公開され、一般投資家がこれを参考にして、売買を行っていることと捉える。この問題をマーケット・マイクロストラクチャー、VPINを用いて分析する。

## 2 VPIN

### 2.1 概要

本稿では、VPIN (Volume-Synchronized Probability of Informed Trading) と呼ばれるマーケット・マイクロストラクチャーの理論を用いて、仕手株を分析する。このVPINは、Easley, et al. [1]が提唱した短期的な市場変動の予兆を捉える指標であり、情報の非対称性の程度を推計するPIN (Probability of Informed Trading, Easley, et al. [4])を基礎として、

<sup>1</sup> 連絡先：大和大学 政治経済学部  
(〒564-0082 大阪府吹田市片山町 2-5-1)  
[kikkawa.mitsuru@yamato-u.ac.jp](mailto:kikkawa.mitsuru@yamato-u.ac.jp)

本稿の内容は、筆者の個人見解を表すものであり、所属組織の見解を示すものではない、また本稿の全ての誤り等は、筆者の責に属するものである。

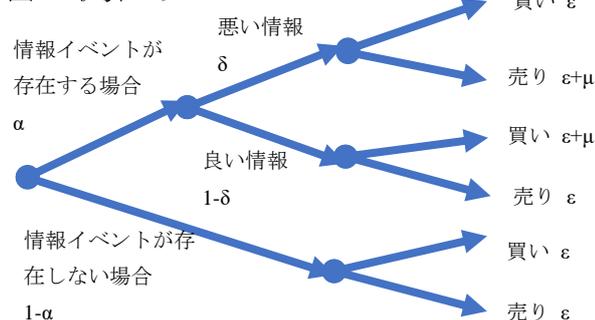
発展させたものである。Easley, et al. [1]では、事後的な計測ではあるものの E-mini S&P 500 futures の VPIN を計測し、2010 年 5 月 6 日特別な要因がないにもかかわらず、ダウ工業株価平均が約 1000 ドル(9%)暴落したフラッシュ・クラッシュの予測に成功したと主張し、クラッシュが発生する以前から市場で情報の非対称性が拡大し、価格形成が不安定化する危険性が高まっていたと指摘した。

この VPIN の短期的な市場変動の予測能力についての議論は進展しているものの、現時点においても VPIN を巡る論争は続いており、その予測能力の評価は定まっているとは言い難い。詳細については、脇屋、大屋[5]を参考にされたい。

## 2.2 理論モデル

市場には、PIN モデルと同様に、私的情報及び公的情報が利用可能な情報投資家と公的情報のみ利用可能な非情報投資家、一般投資家の 2 種類の投資家がいる。私的情報を持つ情報が発生する確率  $\alpha$  とし、それが良い情報である確率は  $(1 - \delta)$ 、悪い情報である確率は  $\delta$  とする。そして、その情報に基づき情報投資家が平均的に出す注文を  $\mu$  とし、公的情報に基づく平均的な発注は  $\varepsilon$  とする。この状況で、私的情報がもたらされた場合、それが良い情報であるなら情報投資家は買い注文  $\mu$  を出すため、買い注文の合計は平均  $\varepsilon + \mu$  となり、 $\mu$  の分だけプラスとなる。それに対して、売り注文は平均  $\varepsilon$  に変わりはない。逆に、情報投資家が得た私的情報が悪い情報の場合、売り注文の合計は平均  $\varepsilon + \mu$  となり、買い注文は平均  $\varepsilon$  となる(図 1)。

図 1 取引ツリー



VPIN は情報の非対称性の程度を測る注文フロー(買いと売りの差額を集計したもの)の不均衡を

取引高及び価格から算出するもので、特に本稿では、clock time 方式<sup>2</sup>を採用し、データを集約する。

式(2.1)及び(2.2)において、第  $\tau$  番目の取引高合計を  $V_\tau^B + V_\tau^S$  とし、それぞれ  $V_\tau^B$  は買い主導による取引高、 $V_\tau^S$  は売り主導による取引高を意味する<sup>3</sup>。また、第  $i$  番目の bar の取引高に、標準正規分布の累積分布関数  $Z(\cdot)$  を用いて、取引高  $v_i$  を買い主導による取引高もしくは売り主導による取引高に分類する。なお、累積分布関数  $Z(\cdot)$  の計算に必要な  $p_i$  は各 bar を作成した際の最後の約定価格、 $\sigma_{\Delta p}$  は bar 間の価格変化の標準偏差を意味している。

$$V_\tau^B = \sum_{i=t(\tau-1)+1}^{t(\tau)} v_i \cdot Z\left(\frac{p_i - p_{i-1}}{\sigma_{\Delta p}}\right) \quad (2.1)$$

$$V_\tau^S = \sum_{i=t(\tau-1)+1}^{t(\tau)} v_i \cdot \left[1 - Z\left(\frac{p_i - p_{i-1}}{\sigma_{\Delta p}}\right)\right] = V - V_\tau^B \quad (2.2)$$

このとき  $V_\tau^B$  と  $V_\tau^S$  の差について、式(2.3)が近似的に成り立ち、これは注文フローの不均衡の期待値を意味しており、過去一定期間累積した値をその間の取引高全体で規格化した量として定義される。それに対して、 $V_\tau^B$  と  $V_\tau^S$  の合計の期待値は、式(2.4)で求めることができる。

$$E[|V_\tau^S - V_\tau^B|] \approx \alpha \mu \quad (2.3)$$

$$E[|V_\tau^B + V_\tau^S|] = \alpha \mu + 2\varepsilon \quad (2.4)$$

以上により、各時間における  $V_\tau^B$  と  $V_\tau^S$  を得ることができれば、式(2.5)により、その系列の移動平均を求めることで、VPIN の系列を計測することができる。この VPIN は全取引に対する私的情報に基づく取引の占める割合(投資家間の情報の非対称性の程度)を示している。ここで、移動平均を求め際の分母の  $n$  は、VPIN の計測期間である。

$$VPIN = PIN = \frac{\alpha \mu}{\alpha \mu + 2\varepsilon} \approx \frac{\sum_{\tau=1}^n |V_\tau^S - V_\tau^B|}{nV} \quad (2.5)$$

Easley, et al. [1]では、投資家間の情報の非対称性が極度に高まり、市場の急騰急落が予測される際のアラートを出すことを目的として計測する場合、この VPIN の経験累積分布関数(Cumulative distribution function, cdf)を求め、累積確率が 0.99 となる値を閾値として用いることを提案している。

<sup>2</sup> 観測開始時点から

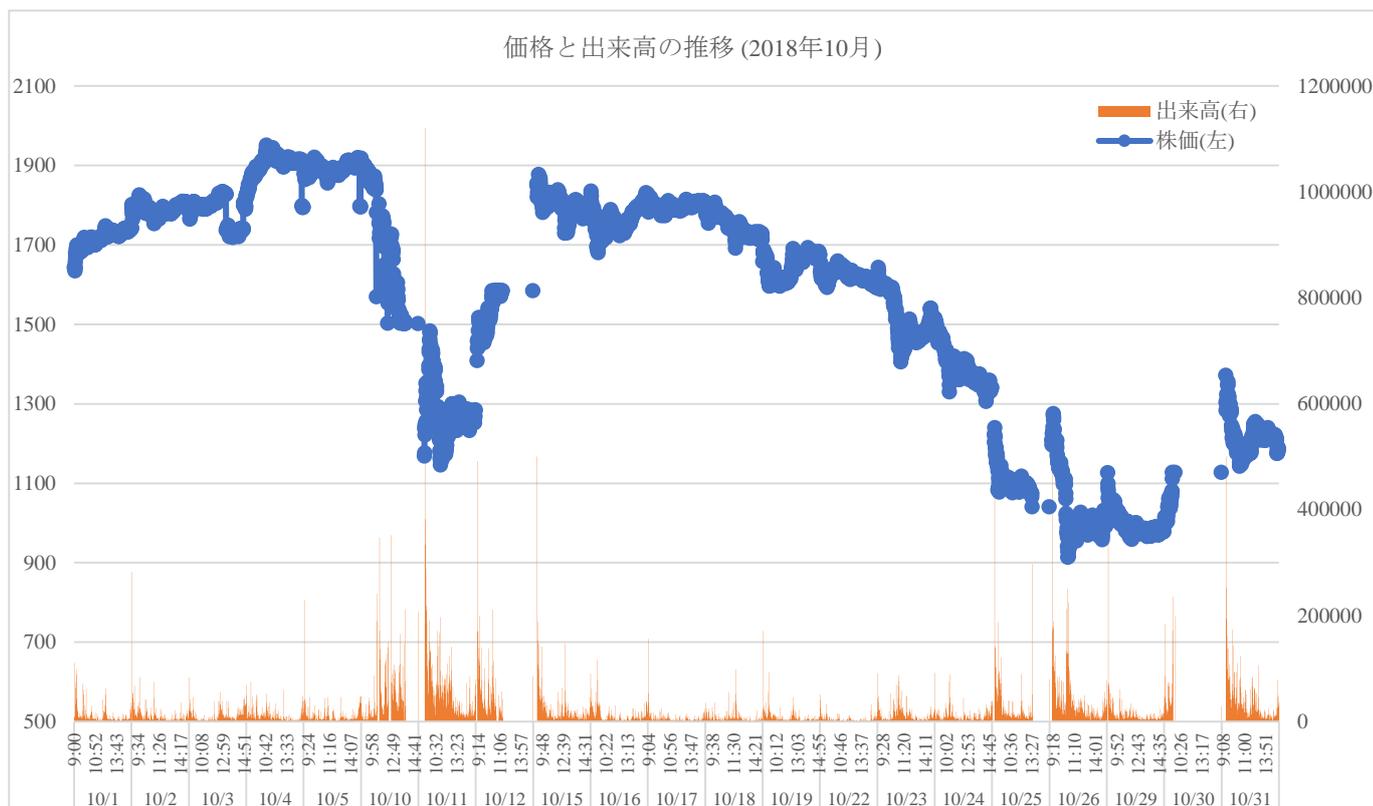
(i) clock time 方式: 決められた時間ごとに

(ii) volume time 方式: 決められた取引高ごと

<sup>3</sup> ここで買い手主導の取引高とは、執行価格が、

(i) 1 時点前の執行価格より高い、(ii) 1 時点前の執行価格と同一かつ 1 時点前が買い手主導であった、とのどちらかに相当する場合の取引高と定義している(売り手主導の取引高も同様)。

図2 株式会社テリロジーの株価と出来高の推移 (2018年10月1日から10月31日, 1分毎に集計)



### 3 実証分析

#### 3.1 分析対象銘柄

本稿では、株式会社テリロジーの株価を取り上げる。この銘柄は、Twitterやネット掲示板等のソーシャルメディアにおいて、売り手、買い手側の間で、激しくやり取りがなされており、いわゆる仕手株のような株価をしている。またこの株においても、イナゴタワーと呼ぶことができるようなものが形成されている(図2)。このイナゴタワーの形成に関して、私的情報を持っている情報投資家が事前に購入し、その後、大量保有報告書、ニュースやTwitter等で情報が公開され(公的情報)、一般投資家がこれを参考にして、売買を行っていると捉える。また相場操縦取引に関しては、仲間内で売買を行い、取引高を大きくして、その後、情報を公表し、売り抜けるといったこともある<sup>4</sup>。このように私的情報を持っている情報投資家の動き・情報から一般投資家がこれを参考にして、売買を行っていることと捉えることが可能である。そこでここでは本稿のような取引参加者間で情報の

非対称のある市場をVPINのモデルにおける「情報投資家」と「非情報投資家」、それぞれ「殿様イナゴ」と「それ以外のイナゴ投資家」と捉える(図3)。

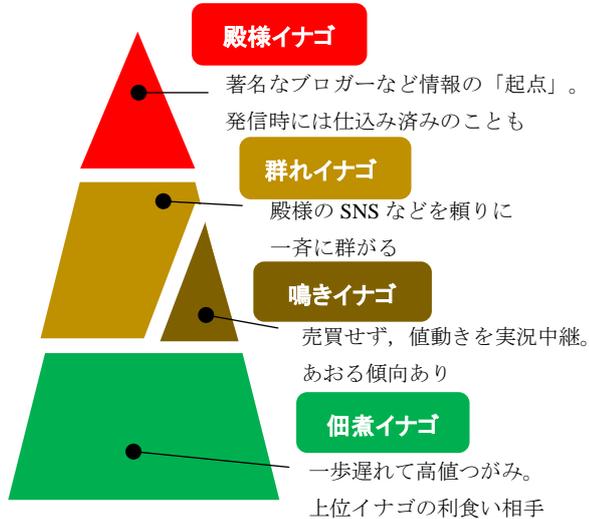
#### (i) 株式の概要<sup>5</sup> (2018年09月30日現在)

登録市場	東京証券取引所 JASDAQ 市場
証券コード	3356
株式公開年月日	2004年12月21日
会社が発行する株式の総数	21,696,000株
発行済株式の総数	15,680,000株
一单元株の式数	100株
株主数	11,407名

<sup>4</sup> <https://www.fsa.go.jp/sesc/support/hukousei/hukousei.htm>

<sup>5</sup> <http://www.terilogy.com/ir/info/index.html>

図3 「イナゴ投資家」のピラミッド構造  
(日経マネー2017年1月号より作成)



(ii) 大株主の状況 (2018年09月30日現在)

株主名	所有株式数(株)	発行済株式総数に対する所有株式数の割合(%)
津吹 憲男	2,461,800	15.70
山田 亨	1,011,800	6.45
阿部 昭彦	764,800	4.87
株式会社 SBI 証券	434,700	2.77

日本トラスティ・サービス信託銀行株式会社	407,000	2.59
松井証券株式会社	401,000	2.55
日本証券金融株式会社	217,500	1.38
株式会社ライブスター証券	163,100	1.04
BNY GCM CLIENT ACCOUNT JPRD AC ISG	151,746	0.96
宇野 辰雄	150,000	0.95

(注)上記のほか、当社所有の自己株式 300,039 株(1.91%)がある。

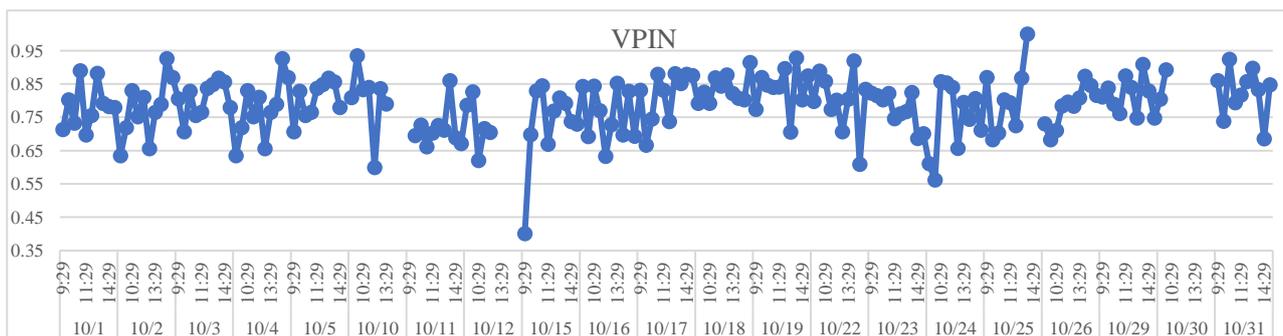
(iii) 株価の変動に大きな影響を与えると考えられる開示情報 (2018年のみ)<sup>6</sup>

6月19日	大株主による当社株式の売却
8月9日	大量保有報告書提出 <sup>7</sup>
9月14日	信用取引規制(11月1日まで)
10月10日	大量保有報告書提出 <sup>8</sup>
12月20日	自己株式を活用した第三者割当による第1回新株予約権の発行に関するお知らせ

### 3.2 VPIN/CDF (VPIN)

JPX データクラウド<sup>9</sup> 現物情報、歩み値(ティック)のデータ(2018年10月)を利用して、実証分析を行った。歩み値(ティック)を1分毎にデータをまとめ、30分毎のVPINを計算した。その推移を図4に、また経験累積分布関数の推移を図5に示した。

図4 VPINの推移(2018年10月1日から31日、30分毎)



<sup>6</sup> <http://www.terilogy.com/ir/index.html>

<sup>7</sup> 上場会社の株券等や投資証券等を5%を超えて保有した場合には、5営業日以内に大量保有報告書を内閣総理大臣(金融庁)に提出しなければならない(金融商品取引法27条の23第1項)。ここでは、1,011,800株(6.45%)新規で株式を取得している(取得平均725円)。

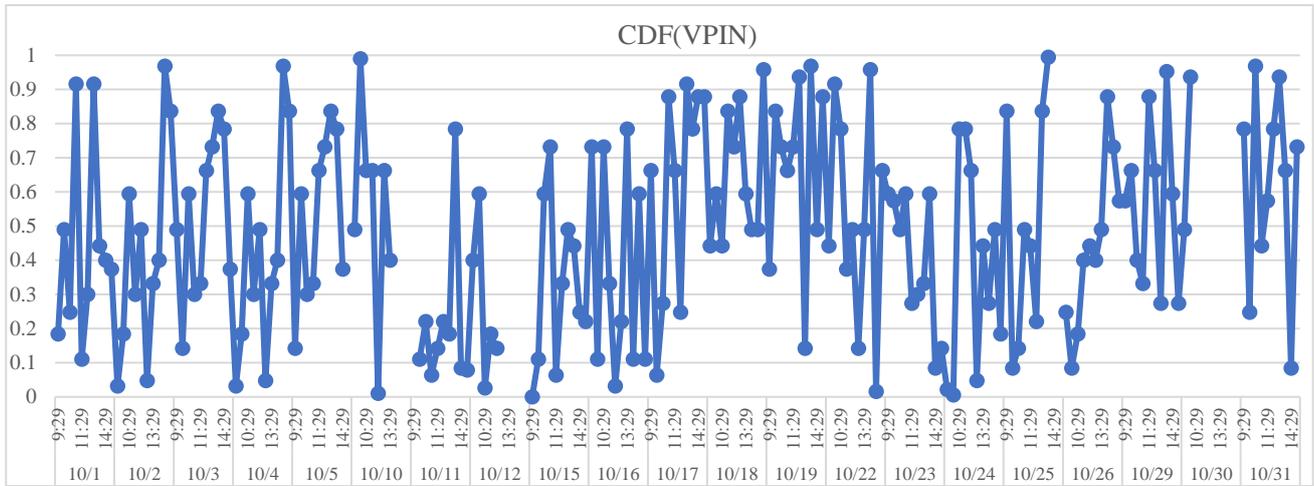
<sup>8</sup> 大量保有報告書を提出した後、株券等保有割合が1%以

上増減した場合やその株式を担保に差し入れるなどの事由が発生した場合、保有目的が変更となった場合その他の大要保有報告書に記載すべき重要な事項の変更が生じた場合には、5営業日以内に変更報告書を提出しなければならない(金融商品取引法27条の25第1項)。

1,651,800株(6.45%→10.53%)

<sup>9</sup> <http://db-ec.jp.co.jp/>

図5 経験累積分布関数(CDF(VPIN))の推移 (2018年10月1日から31日, 30分毎)



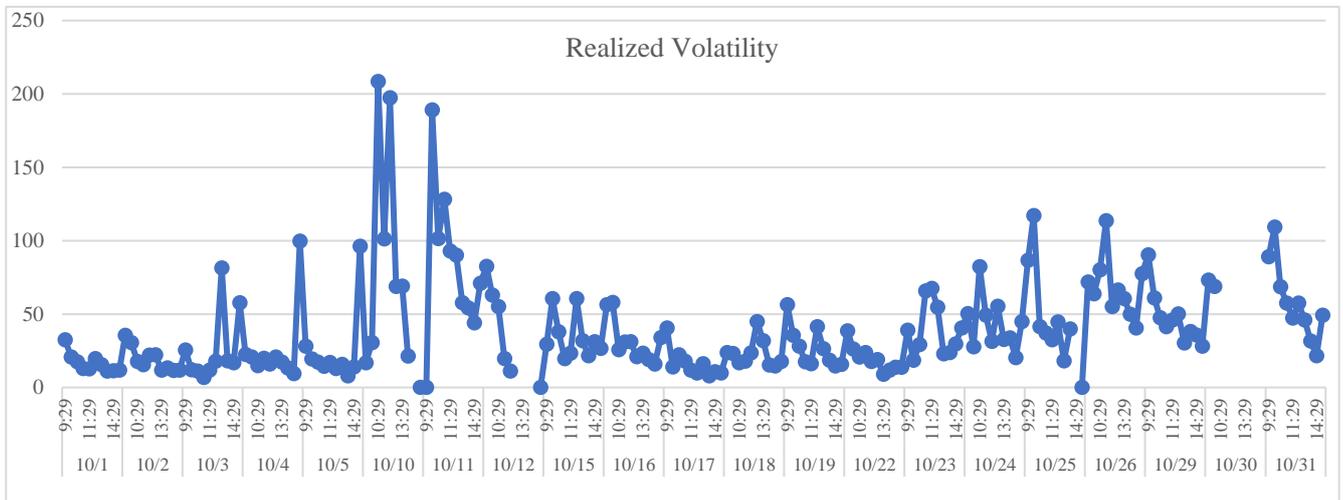
この場合でも、CDF(VPIN)が大きい場合、先行研究と同様に、その後大きな価格変動となっている。情報投資家が大きな売買を行い、価格が動くというよりは、仕込み、情報を広め、この情報に参考にし、売買が行われ、価格が動いていると捉えることができる。

脇屋、大屋[5]においては、VPINと日経平均VIとの関係を調べている<sup>10</sup>が、本株式に関して、オプション市場を利用できないため、Realized Volatility<sup>11</sup>(以下、RV)との関係を調べる。本稿では、1分間隔のリターンの2乗和を用い、30分毎にRVを計算した。

### 3.3 Realized Volatility との関係

#### (1) RV の推移

図6 RVの推移 (2018年10月1日から31日, 30分毎)



<sup>10</sup> 実証分析の結果、VPINは日経平均VIと高い正の相関を持ち、市場が大きく変動するタイミングで、先に変動することを見出している。日経平均VIとは、(株)日本経済新聞社が算出している投資家が日経平均株価の将来の変動をどのように想定しているかを表した指数である。

<sup>11</sup> Realized Volatilityとは、特定の期間内の高頻度データから計算されるリターンの2乗値を合計して得られるボラティリティの推定値のことであり、次のように定義する。

$$RV_i := \sqrt{\sum_{j=1}^M r_{j,i}^2} \times 250 \times 100$$

ただし、 $r_i = p^*(i) - p^*(i-1)$ 、対数価格 $p^*(i)$ 、 $i=1,2,\dots,T$ 、 $T$ : 観測期間とする(日経平均プロフィール[6])。

## (2) VPIN との相関係数

VPIN と RV との相関係数は-0.145, また CDF(VPIN)とは-0.134 となり, 正の相関を持つという先行研究[5]とは異なり, 共にほぼ無相関という結果となった。

## (3) 考察

CDF(VPIN)が 0.99 を超えるのは, (i) 10 月 10 日 10:29 と(ii) 10 月 25 日 13:59 の 2 時点ある。2 時点共に, しばらくすると, 大きく変動している。

### (i) 10 月 10 日 10:29

Twitter などの情報では, 機関投資家が空売りを仕掛けてきた, また以前大量保有報告書を提出した著名な投資家が売り抜けをしたのではということが取り沙汰された<sup>12</sup>。実際, この日に大量保有報告書<sup>13</sup>(10 月 11 日提出分)によると 64 万株, 単価 1,572 円で市場内で取引がされており, 機関投資家が大きな空売りを行ってきたため, これに対抗して著名な投資家が大量に購入したと推測できる。また著名な投資家本人の Twitter でも否定している<sup>14</sup>。

### (ii) 10 月 25 日 13:59

CDF(VPIN)が 1 に近く, その後, 株価はストップ安となっている。この時, RV は小さい。

この場合 Twitter 等では大きな情報はないものの, これ以上買い上げることはないとの安心感から売りが優勢となったと推測できる。

## 4 まとめ

株式会社テリロジーの株価(2018 年 10 月)を VPIN を用いて分析した結果次のことが分かった。

- (1) 先行研究と同様に, CDF(VPIN)が 0.99 を超えるような 1 に近い値を持つ, しばらくすると大きな価格の変動が起きることが確認された。
- (2) 先行研究[5]では, 日経 VI と正の相関があったものの, Realized Volatility との関係は, 無相関であった。

本稿では, 今回取り上げた小型株の場合, 情報投資家が相場を動かすというよりかは, 事前に情報投資家が仕込み, その後情報が公開され, これに追随して相場が動くと思えることが可能であ

る。また, このことは仕手株によく見られる特徴である[2]。

このように VPIN を用いた分析に関して, 大きな市場の変化の予測に関して, 有効であるものの, 小型株の特徴である欠点もある。例えば, 取引開始時刻から寄り付くまでに時間がかかる, ストップ高, ストップ安など, 売り, 買いどちらかに一方に, 注文が大きく偏っている場合も良くある。このような場合, VPIN は有効ではない。

## 注意事項

仮にイナゴタワーを形成させようと, ソーシャルメディアに投稿, 仮にリツイートであったとしても, 相場操縦や風説の流布等となる場合があり得る。

## 参考文献

- [1] Easley, D., Lopez de Prado, M. and O'Hara, M.: Flow toxicity and liquidity in a high-frequency world, *Review of Financial Studies*, Vol., 25, pp. 1457-1493, (2012)
- [2] 湊川啓祐:【最新版】超・短期売買で「仕手株投資」に勝つ!, すばる舎, (2013 年)
- [3] 日本経済新聞: 株価動揺「イナゴ」の塔 突然の急騰, つぶやきが誘発, (2018 年 1 月 16 日)  
<https://www.nikkei.com/article/DGKKZO25687970V10C18A1TJQ00/>
- [4] Easley, D., Kiefer, N. M., O'Hara, M. and Paperman, J.B.: Liquidity information and infrequently traded stocks, *Journal of Finance*, Vol. 51, pp. 1405-1436, (1996)
- [5] 脇屋勝, 大屋幸輔: VPIN を用いた短期的な市場変動予測一日経 225 先物及び日経 225mini を用いた実証分析ー, JPX ワーキングペーパー, Vol.11 (2016 年)
- [6] 日経平均プロフィール: 日経平均株価の各ボラティリティー指標の算式, (2018 年)  
[https://indexes.nikkei.co.jp/nkave/archives/file/users\\_guide\\_jp.pdf](https://indexes.nikkei.co.jp/nkave/archives/file/users_guide_jp.pdf)

年月日	株券等の種類	数量	割合	市場内外取引の別	取引又は処分の別	単価
平成 30 年 10 月 10 日	普通 株式	640,000	4.08	市場内	取得	1,572

<sup>12</sup> <https://matome.naver.jp/odai/2153915371459287901>

<sup>13</sup> <http://cdn.ullet.com/edinet/pdf/S100E9I3.pdf>

<sup>14</sup> <https://twitter.com/Tonpin1234/status/1050372967257927680>

# ビットコインにおけるラフボラティリティとラフ取引高

## Rough volatility and trading volume of Bitcoin

高石哲弥

Tetsuya Takaishi

広島経済大学

Hiroshima University of Economics

**Abstract:** 金融資産価格の収益率には *Stylized facts* と呼ばれる共通に現れる性質があることが知られている。例えば、収益率分布のファットテイル性や絶対値収益率の長期記憶性、ボラティリティクラスターリングなどがある。ボラティリティには長期記憶性が現れるのが知られているが、何故そのような性質が現れるのかは解明されていない。近年、株価の対数ボラティリティ変化の時系列に注目すると、長期記憶性はなく、ハースト指数が 0.5 以下の反持続的な（ラフな）時系列となることが知られてきている。本研究では、ビットコイン時系列に注目し、ビットコインの実現ボラティリティを解析し、対数ボラティリティ変化の時系列に反持続的な性質があるかどうかについて分析をした。また、ボラティリティと取引高や取引数は相関があることから、取引高と取引数の変化にもボラティリティと似た性質が現れると考えられるので、これらについても分析し、反持続的な性質が現れるかどうかを調べた。その結果、ボラティリティ及び取引高と取引数の変化の時系列は反持続性を示すことが分かった。また、これらの時系列はマルチフラクタル性も示すことが分かった。

## 1. はじめに

近年金融資産価格の時系列の統計的性質は精力的に調べられており、多くの金融資産価格に共通に現れる性質があることが知られている。それらの性質は“*Stylized facts*”と呼ばれている[1]。 *Stylized facts* として特に重要な性質は次である。(1) 収益率分布は裾野の厚いファットテイル分布である。(2) 収益率の自己相関は短期の相関である。(3) 絶対値収益率の自己相関は長期相関である。(4) ボラティリティクラスターリングを示す。実証分析では、多くの *Stylized facts* を再現でき、予測精度の高いモデルが有用とされる。そのようなモデルの例として GARCH モデル[2]があり、実証分析でよく利用されている。

*Stylized facts* がなぜ生じるかは十分に理解されていないわけではない。特に、絶対値収益率に長期の自己相関が出る真の原因は不明である。絶対値収益率のべき乗の自己相関も調べられており、株価の場合はべき指数が 1、為替の場合はべき指数が 0.5 付近で最も大きくなることが知られている。この性質は、テイラー効果[3,4,5,6]と呼ばれている。ビットコインにもテイラー効果が確認されており[7]、べき指数が

約 0.4 で最大となることが示されている。

また、絶対値収益率と同様にボラティリティにも長期相関が見られ、ボラティリティ時系列のハースト指数は 0.5 以上と持続的な性質になっている。従って、ボラティリティの時系列をモデル化する場合には、長期記憶性を持ったモデルを利用するのが自然な流れとなる。そのようなモデルとして、対数ボラティリティを非整数ブラウン運動でモデル化したものがある[8]。この時、長期記憶性を持たせるためにモデル内のハースト指数は 0.5 以上が設定される。

一方で、株価の対数ボラティリ（実現ボラティリティ）の変化量の時系列の実証分析から、ハースト指数が 0.5 以下となっており、変化量の時系列は反持続的となっていることが近年明らかとなってきた。そこで、ハースト指数が 0.5 以下の非整数ブラウン運動でボラティリティをモデル化する試みも行われている[9]。Ref.[9]では、ハースト指数が 0.5 以下の性質を持つボラティリティをラフボラティリティと呼んでいる。

本研究では、ビットコイン価格に注目し、対数ボラティリティ変化量の時系列のハースト指数を計算し、株価と同様に反持続的な性質が現れるかどうかを調べる。また、Ref.[9]では、時系列はモノフラクタ

ルであると結論されているが、本研究では Ref.[10,11]の手法によるマルチフラクタル解析を行い、対数ボラティリティ変化量にマルチフラクタル性があるかどうかを調べる。ビットコインの収益率時系列には、すでにマルチフラクタル性があることが知られている[12]。

## 2. ビットコイン価格

本研究では、COINBASE 取引所の Tick データを利用した[13]。利用したデータ区間は、2015年1月28日から2019年1月6日である。Tick データから様々なサンプリング間隔の収益率データを作成し、実現ボラティリティを計算する。本研究では、5分間隔の収益率データを用い、次章で述べる手法によって実現ボラティリティを計算する。

図1はTick データから作成した日次収益率の時系列を表している。また、図2と3はそれぞれ日次取引高と日次取引数の時系列である。

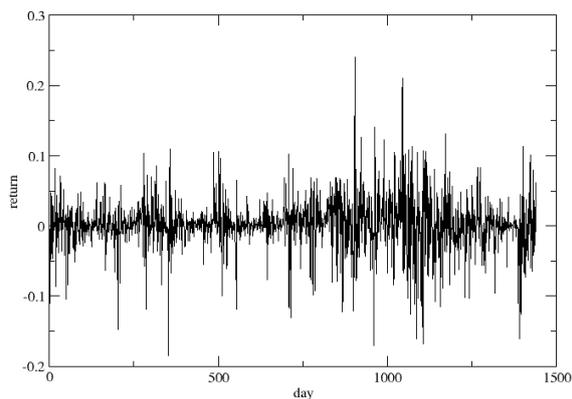


図1：ビットコイン価格の日次収益率

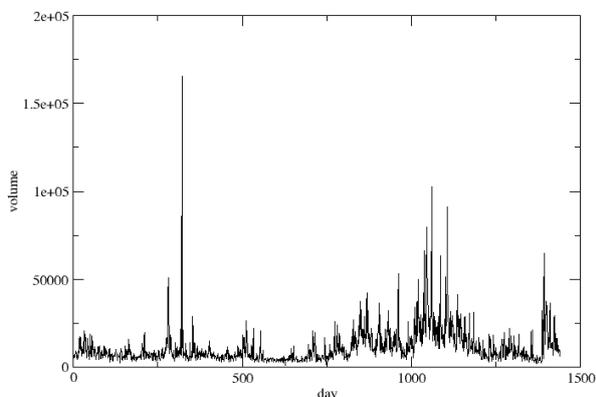


図2：日次取引高

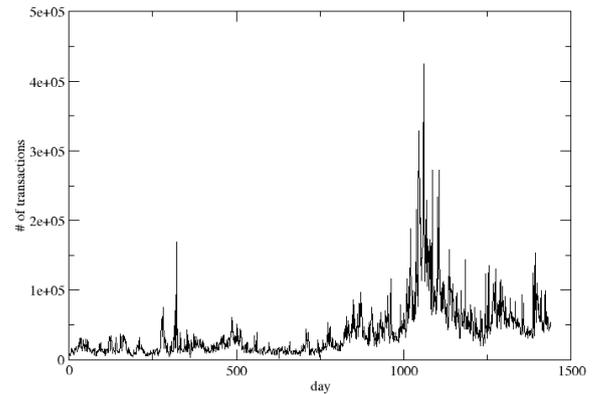


図3：日次取引数

## 3. 実現ボラティリティ (Realized volatility)の計算

本研究では、実現ボラティリティをボラティリティとして、対数ボラティリティの変化の時系列を分析する。t日におけるある時刻  $t_0$  から  $t_0+T$  までの期間  $T$  を  $n$  個で分割し、 $i$  番目の収益率を

$$r_t(t_0 + i \Delta t) = \ln P(t_0 + i \Delta t) - \ln P(t_0 + (i-1) \Delta t) \quad (1)$$

とする。ここで時間間隔  $\Delta t$  は  $\Delta t = T/n$  であり、これはサンプリング時間を表す。この時、期間  $T$  におけるサンプリング時間  $\Delta t$  でのRVは分割した収益率の2乗を足し合わせることによって、以下のように計算される。

$$RV_t^{(\Delta t)} = \sum_{i=1}^n r_t^2(t_0 + i \Delta t) \quad (2)$$

ここで、対数価格  $\ln p(t)$  が以下の確率過程に従っているとす。  $W$  は標準ブラウン運動、 $\sigma(t)^2$  はスポットボラティリティを表す。

$$d \ln p(t) = \sigma(t) dW \quad (3)$$

このとき、(2)式はサンプリング時間ゼロの極限で Integrated volatility  $\int_{t_0}^{t_0+T} \sigma(t)^2 dt$  に収束することが示される。

Zhou(1996)は対数価格に独立なノイズが加わるモデルを導入し、その時のRVにどのようなバイアス加わるかを計算した。対数価格+ノイズのもとで観測される収益率が以下のように修正される。

$$r^*(s) = r(s) + \eta(s) \quad (4)$$

ここで、 $\eta(s)$ は収益率に対して独立なノイズである。

この時、観測されるRV\*は

$$RV_t^{*(\Delta t)} = RV_t^{(\Delta t)} + \sum_{i=1}^n r_t(t_0 + i\Delta t) \eta(i) + \sum_{i=1}^n \eta^2(i) \quad (5)$$

となる。右辺の第2項は収益率とノイズが独立であれば期待値はゼロとなる。第3項がノイズによるバイアスにあたり、ノイズの分散を $\omega^2$ とすると期待値

は $n\omega^2$ となり、 $n$ に比例して大きくなる。また、サンプリング時間は $\Delta t=T/n$ であるから、バイアスはサンプリング時間に反比例することになる。

バイアスの影響を修正する手法として、Hansen と Lunde による方法[14]があり、彼らの方法では、RVの平均が日次収益率の分散と一致するようにRVに修正ファクター(定数)をかける。RVに定数を掛けただけの時系列のハースト指数等の性質は変化しないので、本研究では修正をかけていないRVの時系列を取り扱う。

図4はサンプリング間隔5分の収益率から計算した日次RVについて、RV<sup>1/2</sup>の時系列を表している。更に、RV<sup>1/2</sup>の変化

$$Rt = \log(\sigma_t) - \log(\sigma_{t-1}) \quad (6)$$

の時系列を図示したのが図5である。ここで、 $\sigma_t \equiv RV_t^{1/2}$ とおいている。図1の収益率に比べると非常にスムーズな変動となっているように見える。

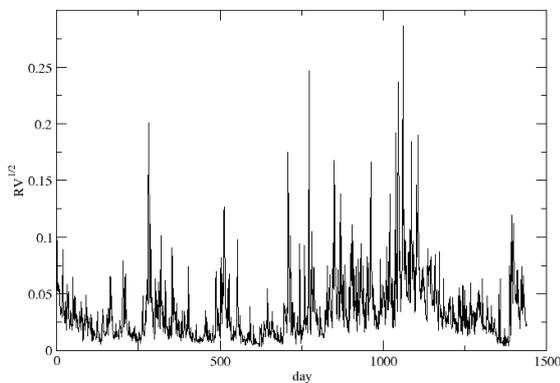


図4：サンプリング間隔5分のRV<sup>1/2</sup>の時系列

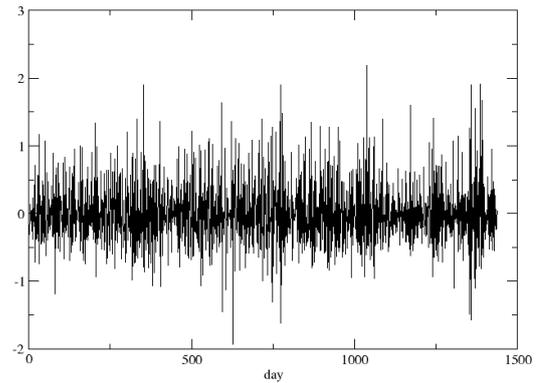


図5：RV<sup>1/2</sup>の変化の時系列

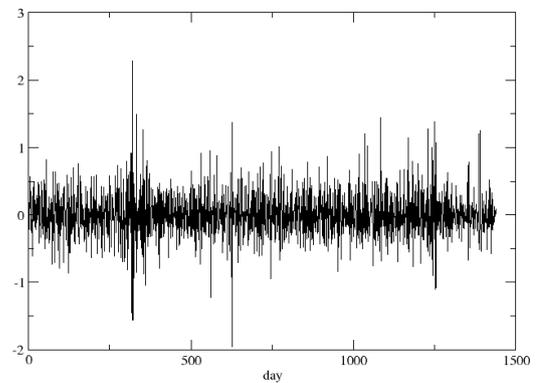


図6：取引高の変化の時系列

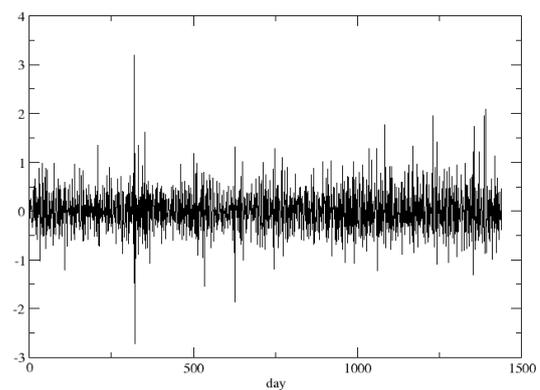


図7：取引数の変化の時系列

同様に、取引高と取引数の変化について図示したのがそれぞれ図6と図7である。取引高と取引数の変化は以下の定義である。

$$R_t = \log(V_t) - \log(V_{t-1}) \quad (7)$$

ここで、 $V_t$ は  $t$  日における取引高または取引数を表している。図 6 と 7 も図 5 と同様のスムーズな振る舞いが見られる。

#### 4. マルチフラクタル解析

本研究では、Kantelhardt らによる Multifractal detrended fluctuation analysis (MFDFA) の方法 [10] によってマルチフラクタル解析を実行し、一般化ハースト指数を求めた。MFDFA 法は以下の手続きから成る。

- ① オリジナルの時系列  $\{x_t, t=1, \dots, N\}$  から次のプロフィール  $y(k)$  を作成する。

$$y(k) = \sum_{i=1}^k (x_i - \bar{x}) \quad (8)$$

ここで、 $\bar{x}$  は時系列  $x_t$  の平均値である。

- ② プロファイル  $y(k)$  を長さ  $s$  の  $N_s = N/s$  個のセグメントに分け、セグメント内でトレンドを除去したデータの分散を求める。具体的には以下の、 $\nu$  番目のセグメント、 $\nu = 1, \dots, N_s$  に対して  $F^2(s, \nu)$  を計算する。

$$F^2(s, \nu) = \frac{1}{s} \sum_{i=1}^s (y[(\nu-1)s+i] - p_\nu(i))^2 \quad (9)$$

(9) 式中の  $p_\nu(i)$  はトレンドを除去するための関数で、本研究ではセグメント内のデータを 3 次関数でフィットした関数を利用した。また、 $N$  は  $s$  の倍数とは限らないので、その場合、最後の端数のデータが残ってしまう。これらのデータも利用するために、最後のデータから順番に並べ、上記の手続きを繰り返す。具体的には、 $\nu = N_s + 1, \dots, 2N_s$  に対して、以下を計算する。

$$F^2(s, \nu) = \frac{1}{s} \sum_{i=1}^s (y[N - (\nu - N_s)s + i] - p_\nu(i))^2$$

$$(10)$$

- ③ 計算した分散を利用して  $q$  次の揺らぎ関数を以下のように定義する。

$$F_q(s) = \left( \frac{1}{2N_s} \sum_{\nu=1}^{2N_s} [F^2(s, \nu)]^{q/2} \right)^{1/q} \quad (11)$$

もし、時系列が長期のべき的相関を持つなら、(11) 式は以下のように振る舞うことが期待される。

$$F_q(s) \sim s^{h(q)} \quad (12)$$

ここで、 $h(q)$  は一般化ハースト指数とよばれるものである。 $q = 2$  のとき、 $h(2)$  はハースト係数に一致する。時系列  $h(q)$  が  $q$  に依存するとき、マルチフラクタル性を持つ。ガウス時系列の場合、 $h(q)$  は  $h(2)$  の場合と変わらず、マルチフラクタル性は現れない。

- ④ (12) 式の振る舞いから一般化ハースト指数  $h(q)$  を求める。

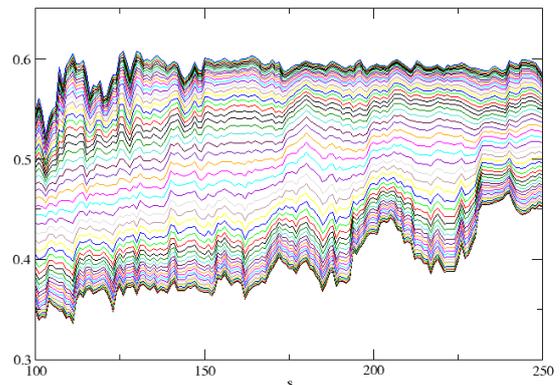


図 8 : 揺らぎ関数  $F_q(s) \sim s^{h(q)}$

図 8 は  $RV^{1/2}$  の対数変化の時系列のデータから揺らぎ関数 (11) 式をもとめ、両対数でプロットした図である。 $q = -25 \sim 25$  までの様々な  $q$  において揺らぎ関数を計算している。一番下のグラフが  $q = -25$  に対応し、一番上は  $q = 25$  に対応する。これらのグラ

フを直線でフィットし、得られた傾きが一般化ハースト指数に対応する。

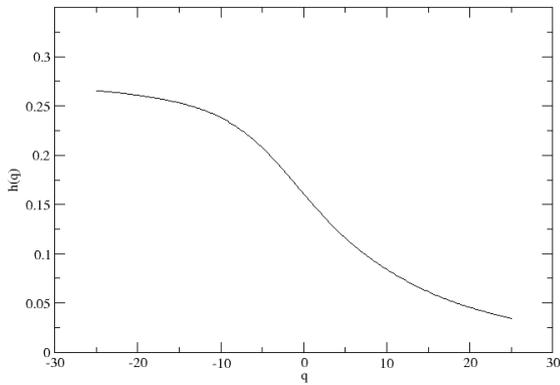


図 9 :  $RV^{1/2}$  変化の時系列の一般化ハースト指数

$h(q)$

図 9 は図 8 の結果からも求めた一般化ハースト指数  $h(q)$  を図示したものである。 $h(q)$  は全領域で 0.5 以下となっており、反持続的となっている。また、 $h(q)$  は  $q$  に依存して変化しており、マルチフラクタル性を有している。

同様に、図 10 と 11 はそれぞれ取引高変化と取引数変化の一般化ハースト指数を求めたものである。これらも、指数の値が 0.5 以下となっており、反持続性を示し、かつ  $q$  による依存性がありマルチフラクタル性を有している。

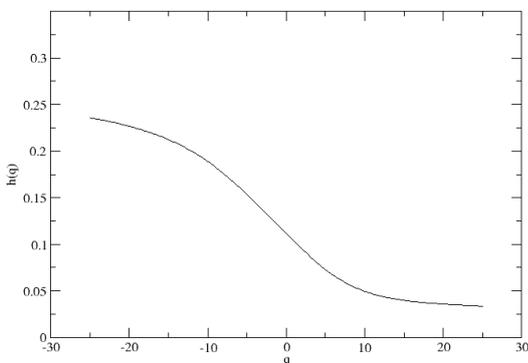


図 10 : 取引高変化時系列の一般化ハースト指数

$h(q)$

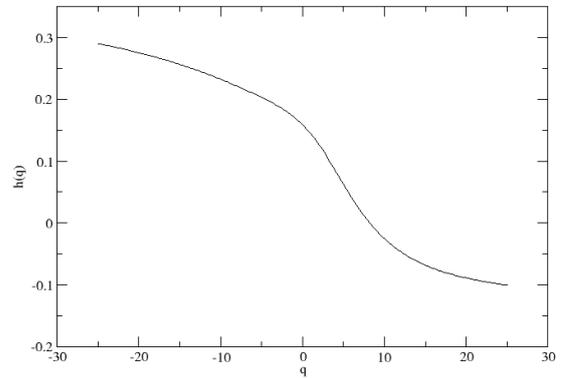


図 11 : 取引数変化時系列の一般化ハースト指数

$h(q)$

表 1 はハースト指数  $h(2)$  の値をまとめたものある。ハースト指数は 0.1 前後であり、0.5 よりもかなり低い値となっている。Ref.[9]も株価について 0.1 程度のハースト指数の値を得ている。

表 1 : ハースト指数  $h(2)$

	$RV^{1/2}$	取引高	取引数
$h(2)$	0.141	0.0950	0.126

## 6. まとめ

本研究では、ビットコイン価格の実現ボラティリティを計算し、その対数変化の時系列を分析した。その結果、時系列はハースト指数が 0.5 以下となっており、反持続的性質を持つことが分かった。また、一般化ハースト指数は  $q$  の値によって変化し、マルチフラクタル性があることが分かった。取引高及び取引数の対数変化の時系列も同様に反持続的でマルチフラクタル性があることが分かった。よって、Ref.[9]の言葉を借りれば、ビットコインのボラティリティ及び取引高、取引数はラフであるといえる。

## 謝辞

本研究の一部は JSPS 科研費 18K01556 の助成による。

## 参考文献

- [ 1 ] R.Cont, Empirical properties of asset returns: stylized facts and statistical issues. Quantitative Finance 1, 223–236,

(2001)

- [ 2 ] T. Bollerslev, Generalized autoregressive conditional heteroskedasticity, *Journal of Econometrics* 31, 307-327, (1986)
- [ 3 ] S. J. Taylor, *Modelling financial time series*, John Wiley & New jersy, 1986.
- [ 4 ] Z. Ding, C. W. Granger, R. F. Engle, A long memory property of stock market returns and a new model, *Journal of empirical finance* 1 (1) , 83–106, (1993)
- [ 5 ] Z. Ding, C. W. Granger, Modeling volatility persistence of speculative returns: a new approach, *Journal of econometrics* 73 (1), 185–215, (1996)
- [ 6 ] M. Dacorogna, R. Gencay, U. Müller, O. Pictet, R. Olsen, *An introduction to high-frequency finance*, Academic Press, 2001.
- [ 7 ] T.Takaishi, T.Adachi, Taylor effect in Bitcoin time series, *Economics Letters* 172, 5-7, (2018)
- [ 8 ] F. Comte and E. Renault. Long memory in continuous-time stochastic volatility models. *Mathematical Finance*, 8(4):291–323, (1998).
- [ 9 ] J. Gatheral, T. Jaisson & M. Rosenbaum, Volatility is rough, *Quantitative Finance*, 18, 933-949, (2018)
- [ 1 0 ] J.W.Kantelhardt et al., Multifractal detrended fluctuation analysis of nonstationary time series, *Physica A* 316, 87-114, (2002).
- [ 1 1 ] C.K. Peng, et al., Mosaic organization of DNA nucleotides, *Phys. Rev. E* 49, 1685, (1994)
- [ 1 2 ] T. Takaishi, Statistical properties and multifractality of bitcoin, *Physica A* 506, 507–519, (2018)
- [ 1 3 ] Bitconcharts, <https://api.bitcoincharts.com/v1/csv/>
- [ 1 4 ] P.R. Hansen, A. Lunde, A forecast comparison of volatility models: does anything beat a GARCH(1, 1)? *J. Appl. Econometrics* 20 (7), 873–889, (2005)

# インフルエンサーのツイートを用いた暗号資産の価格変化予測

## Prediction of Crypto-Asset Price using Influencer Tweets

山本 寛史<sup>1\*</sup> 坂地 泰紀<sup>1</sup> 松島 裕康<sup>1</sup> 山下 雄己<sup>2</sup>  
大澤 恭平<sup>2</sup> 和泉 潔<sup>1</sup> 島田 尚<sup>1</sup>

Hirofumi Yamamoto<sup>1</sup> Hiroki Sakaji<sup>1</sup> Hiroyasu Matsushima<sup>1</sup> Yuki Yamashita<sup>2</sup>  
Kyohei Osawa<sup>2</sup> Kiyoshi Izumi<sup>1</sup> Takashi Shimada<sup>1</sup>

<sup>1</sup> 東京大学

<sup>1</sup> The University of Tokyo

<sup>2</sup> 株式会社電通国際情報サービス

<sup>2</sup> Information Services International-Dentsu, Ltd.

**Abstract:** 現在、暗号資産は金融分野で注目を集めており、代表的な暗号資産の一つであるビットコインの1日の取引量は5億を超える。本研究では、ソーシャルネットワークサービス上で、強い影響力を持ったインフルエンサーと呼ばれる人々の暗号資産に関するツイートの影響に着目する。我々はインフルエンサーのツイートが暗号資産価格に影響すると考え、インフルエンサーのツイートを用いて、ビットコイン価格の上昇/下降を予測する手法を提案する。インフルエンサーのツイートを収集し、それを言語処理の手法を用いて特徴抽出し、機械学習に用いる素性を生成した。実験の結果、我々はインフルエンサーツイートが暗号資産の価格に影響する可能性があることを示唆した。

## 1 はじめに

暗号資産<sup>1</sup>は現在、金融の分野において多くの投資家や研究者の関心を集めている。Bitcoin(BTC)[Nakamoto 08]は、そのような暗号資産の1つで、1日の取引量は50億を超える。暗号資産のために考案されたブロックチェーン技術は、他の分野への応用が期待されているため、エンジニアからの注目も集めている。このように様々な分野からの関心があり、ブロックチェーンテクノロジーに関するトピックについて、多くのツイートがされている。一方で、Twitterのデータ活用についても機関投資家から注目され始めている。2011年に、Bollenらはつぶやきから得られた気分状態がダウ工業平均株価の予測に役立つことを示しており[Bollen 11]、彼らの研究は多くの研究者や投資家に大きな影響を与えた。我々は、この結果を参考にして、ツイートを使用して株価ではなくBTC価格を予測することを目的としている。具体的には、ソーシャルネットワーキングサービス(SNS)においてユーザーに大きな影響を与えるインフルエンサーと呼ばれるユーザーの暗号資産に関するつぶやきと暗号資産の価格に着目した。我々はイ

ンフルエンサーのつぶやきは暗号資産の価格に影響を与えている、つまり、インフルエンサーのつぶやきは暗号資産に影響を与えると仮定している。この仮説を検証するために、インフルエンサーのつぶやきを使ってBTC価格を予測する実験を行った。TwitterデータとBTC価格を使用する方法の予測可能性が、BTC価格のみを使用する方法よりも優れている場合、私たちの仮説が証明されると考えられる。

我々は、以下に示す方法でインフルエンサーのつぶやきを使用してBTC価格が増減するかどうかを予測した;まず、インフルエンサーのつぶやきとBTCの価格のデータを収集する。次に、自然言語処理技術を使用してツイートから特徴を抽出し、機械学習に与える入力データとする。与えられた入力データに対して、BTC価格の上昇/下降を分類する出力として学習させる。最後に、学習したモデルを用いてインフルエンサーのツイートからBTC価格を予測する。

我々はこの実験においてニューラルネットワーク、サポートベクターマシン(SVM)[Hearst 98]、ランダムフォレスト[Breiman 01]など、いくつかの機械学習方法を採用し、仮説を確認するための実験を行った。

\*連絡先: 東京大学

E-mail: yamamoto-hirofumi277@g.ecc.u-tokyo.ac.jp

<sup>1</sup>暗号資産はしばしば「暗号通貨」と呼ばれる。しかし、日本の金融庁は暗号通貨を「暗号資産」と呼ぶべきであると論じているので、本稿ではそれを暗号資産と呼ぶ。 <https://www.fsa.go.jp/news/30/singi/20181214.html>

## 2 暗号資産価格予測手法

ここでは、本手法と機械学習方法のために選択した特徴量について説明する。本手法の新規性は、将来の暗号資産価格を予測するためにツイートデータと暗号資産価格の両方を使用することである。以下の節では、特徴量抽出とモデルについて説明する。

### 2.1 特徴量

最初に、英語と日本語それぞれのつぶやきの0.5%以上に含まれる名詞、動詞、形容詞を選択し、それらの重要性をTFIDFによって評価した。TFIDF( $w, t$ )は次の式で計算される。

$$TFIDF(w, t) = tf(w, t) \log_2 \frac{N}{df(w)}, \quad (1)$$

ここで、 $tf(w, t)$ は、ツイート $t$ 内の単語 $w$ の頻度、 $N$ は、学習データセット内のツイートの数、 $df(w)$ は、単語 $w$ のツイート頻度をそれぞれ示している。

この実験には2種類の入力を選択された;(1)ツイートテキストのTFIDFデータのみの入力、(2)TFIDFデータにいいねの数とリツイート数、ツイートしたユーザーのフォロワー数、および前日からのBTCの価格の変化率の4つをあわせた入力である。ただし、これらの入力はbiLSTMには使用されず、代わりにツイートデータのword2vec[Mikolov 13]<sup>2</sup>(200次元)が入力として使用される。

### 2.2 機械学習手法

この節では、実験で使用した機械学習方法を述べる。我々はツイートからBTCの価格変動を予測するために、ロジスティック回帰(LR)、ランダムフォレスト(RF)、および多層パーセプトロン(MLP)を使用した。LRとRFにはScikit-learn<sup>3</sup>で用意されているものを採用した。MLPとbiLSTMはPytorch<sup>4</sup>を使って実装した。MLPは、1つの入力層、1つの隠れ層、および1つの出力層で構成されており、活性化関数として双曲線正接関数(tanh)を採用した。各隠れ層は100単位で構成されている。biLSTMも、1つの入力層、1つの隠れ層、および1つの出力層で構成されている。

### 2.3 本手法

BTCの価格とツイートデータの間をさらに調べるために、以下のモデルを提案する(Figure 1)。まず、前

<sup>2</sup><https://radimrehurek.com/gensim/>

<sup>3</sup><http://scikit-learn.org/stable/>

<sup>4</sup><https://pytorch.org>

日からのBTCの価格変動が1%以上の場合、LRを用いてモデルの係数と切片を計算する。次に、切片と係数を使用して、結果が1になる確率を次の式を使用して計算する。

$$probability = \frac{1}{1 + e^{-\beta - \alpha \cdot v}} \quad (2)$$

ここで、 $\alpha$ は係数、 $\beta$ は切片、 $v$ はTFIDFと、LRの入力として使用されるその他のツイートデータをつなげたベクトルである。式2は、図1に示すようにVectorizeと呼ばれる。RF入力データは以下のように生成される。

**Step 1:** ツイートのテキストからTFIDFを計算する。

**Step 2:** ツイートの“いいね”の数とリツイート数、およびそのユーザーのフォロワー数を、計算したTFIDFにつなげる。これは「ツイートデータ」と呼ばれる。

**Step 3:** Step 2のデータによってLRを訓練し、その係数と切片を計算する。この訓練されたLRは、Figure 1における「Learned LR」である。

**Step 4:** ツイートごとに、LRの係数と切片、ツイートデータ(Formula 1)でBTCの価格が値上がりする確率を計算する。この確率を「LRスコア」とする。このスコアは、図1の入力ベクトルの「Vector B」部分のそれぞれの数である。

**Step 5:** 毎分、前日からのBTC価格の変化率を計算する(これを「変化率」と呼ぶ)。これはFigure 1の入力ベクトルの「Vector A」部分である。

**Step 6:** 1分間にツイートされた12ツイートのLRスコアを、BTCの値段が翌日に1%以上変動した時点から1時間前までの変動率につなげる。ツイートが足りない分は0.5に置き換える。これがRFの入力データであり、Figure 1の入力ベクトルである。

## 3 評価実験

本節では、本手法を評価する。BTCの価格変動とインフルエンサーのつぶやきの関係を調べるために、次の実験を行った。

- 本手法による予測とツイートデータなしの予測の精度の違いを確かめる実験。
- 入力としてword2vecを使ったbiLSTMによる実験。
- 本手法と同じ条件の、他のアプローチによる実験。

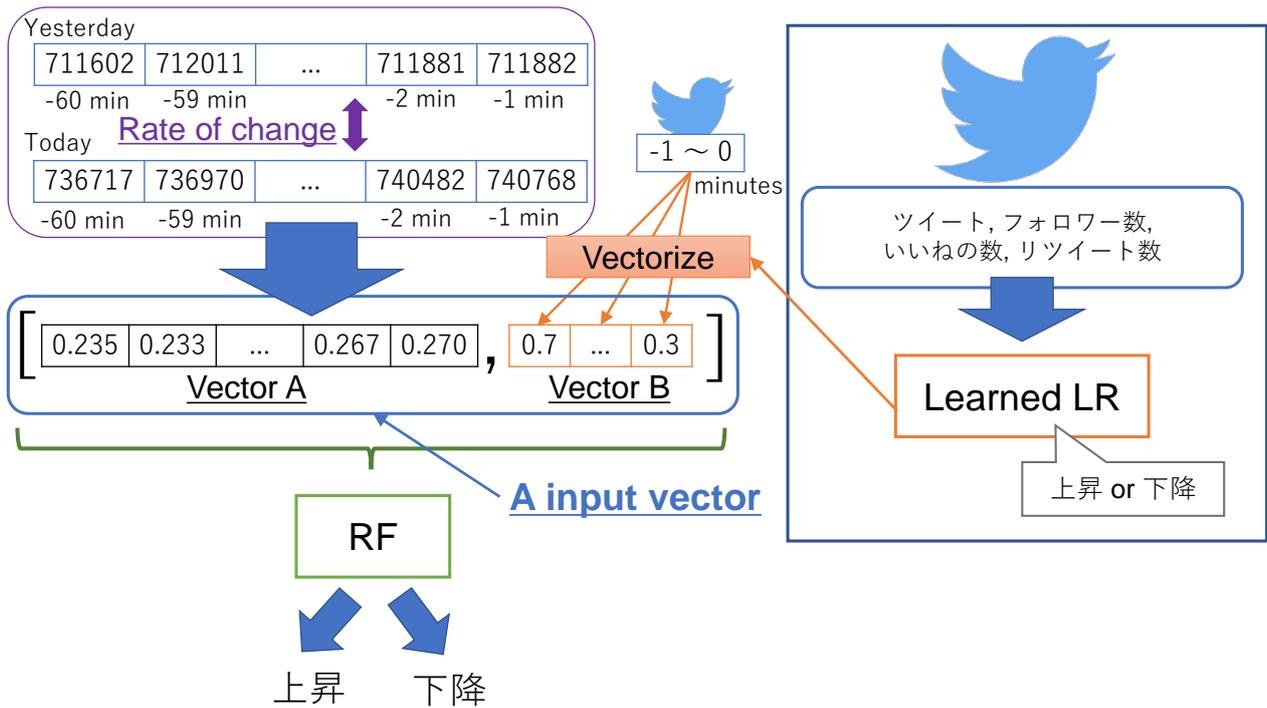


図 1: 本手法

表 1: ツイートの例

No.	Tweet
1	NY株大幅続落, 市場関係者の見方
2	米インテル, 振るわぬ株価と狭まる包囲網
3	南海電鉄, 台風で浮かんだ訪日客銘柄の課題
4	GMO, 仮想通貨で再出発 ホリエモンの助言
5	株も先物も 総合取引所実現へ, 政府が年内答申
6	ヤマトHDが「空飛ぶトラック」, 米社と開発 人手不足解消へ無人輸送機
7	放置預金に注意, 10年で国が召し上げ 来年から

さらに、我々は BTC の価格だけでなく、取引量とツイートも関連している可能性があると仮定した。そのため、ツイートから取引量の変化を予測する実験も行った。

### 3.1 実験設定

実験を行う上での設定について説明する。

・被説明変数: 本研究では、予測対象である BTC の価格について非説明変数である出力値について大まかに 3 ケース用意した。まず、(1)BTC の価格が一定期間後に上昇または下降するかの予測である。1日後、1週間後、

2週間後という 3つの期間を考えた。次に、(2)BTC の取引金額が一定期間後に増減するかどうかを予測することである。これについても、価格の場合と同様に 3つの期間が考慮された。最後に、(3)BTC の価格が1日後に 1%以上上昇したとき、または減少したときに限定し、価格が上昇または下降するかどうかを予測した。  
・入力変数 (ツイート) の種類の組み合わせ: ツイートは次の 3つの基準に従って分類された: (1) 言語 (日本語または英語), (2)BTC または GEN (一般) としてタグ付けされているかどうか, (3) ツイート後に BTC の価格が 1%以上変動したかどうか。ここで、ツイートの BTC 関連のトピックが含まれている場合、そのツイートは BTC とタグ付けされていた。さらに、ツイートに暗号資産関連の一般的なトピックが含まれている場合、それらは GEN とタグ付けされていた。これらの基準の組み合わせに基づいて、我々は 8種類の入力を得た。

### 3.2 評価データ

ここでは、私たちの方法を評価するためのデータを生成する方法を示す。MeCab<sup>5</sup> を日本語の、spaCy<sup>6</sup> を英語の形態素解析のために使用した。RT で始まるツイートは、リツイートであるため削除した。評価には

<sup>5</sup><http://taku910.github.io/mecab/>

<sup>6</sup><https://spacy.io/>

2018年7月16日から10月24日までのツイートデータを使用した。我々は、以下のようにしてインフルエンサーのツイートを収集した。まず、暗号資産に関連するツイートを頻繁に投稿する人々を調査し、彼らのフォロワーをたどった。そして、私たちはこれらの人々の中からインフルエンサーを選び、彼らのつぶやきを集めた。7月16日から9月24日までのツイートデータを学習データとし、10月4日から10月24日までをテストデータとした。

表2に我々のデータの内容を示す。

表2: 入力に使われたツイートの数

	train data	test data
英語	25,986	14,542
日本語	70,400	23,581
英語 (BTC または GEN のタグ)	2,765	1,693
日本語 (BTC または GEN のタグ)	7,915	2,431
英語 (変化率 > 0.01)	16,864	2,552
日本語 (変化率 > 0.01)	47,864	4,305
英語 (BTC または GEN のタグ, 変化率 > 0.01)	1,824	336
日本語 (BTC または GEN のタグ, 変化率 > 0.01)	5,508	413

特徴のうち、TFIDF 値は、Scikit-learn によって正規化した。追加の特徴、すなわち、「いいね」およびリツイート数、前日からの BTC 価格の変化率、およびそのユーザのフォロワー数は、それぞれの絶対値の最大値で割り、最大値は 1 とした。

### 3.3 評価結果

表3は、本手法と、ツイートデータではなく BTC 価格のみを使った RF 予測の予測結果を示している。さらに、本手法と同じデータを使用し、LR, RF, および MLP 法を使用して BTC の価格変動を予測した。これらの実験の入力には翌日までの変化率が 1% 以上の入力のみを使用した。

表3: 予測の結果

	本手法	BTC 価格のみ	LR	RF	MLP
ACC	<b>0.666</b>	0.646	0.435	0.608	0.499
PRE	<b>0.665</b>	0.639	0.344	0.517	0.403
REC	<b>0.605</b>	0.598	0.440	0.435	0.499
F1	<b>0.629</b>	0.613	0.386	0.472	0.446

ここで、「ACC」は accuracy, 「PRE」は precision, 「REC」は recall, 「F1」は f-measure をあらわす。これらの値は以下のように定義される。

	真の結果	
予測	TP	FP
結果	FN	TN

上記のように定義したとき、

$$ACC = \frac{TP + TN}{TP + TN + FP + FN}$$

$$PRE = \frac{TP}{TP + FP}$$

$$REC = \frac{TP}{TP + FN}$$

$$F1 = \frac{2 \times PRE \times REC}{PRE + REC}$$

また、word2vec を入力とし、biLSTM による学習結果は表4のとおりである。

表4: biLSTM の結果

	英語 word2vec			日本語 word2vec		
	1日	1週間	2週間	1日	1週間	2週間
PRE	0.515	0.120	0.424	<b>0.521</b>	0.157	0.411
REC	<b>0.544</b>	0.398	0.480	0.516	0.531	0.499
F1	<b>0.529</b>	0.184	0.450	0.518	0.242	0.451

また、LR, RF, MLP を用いて 1% 以上の変化率で学習した結果は、図2および図3のとおりである。入力データとして、ツイートのテキストに加えて、いいねとリツイート数、前日からの BTC 価格の変化率、およびそのフォロワーのフォロワー数が使用された。英語と日本語のつぶやきでは、BTC または GEN とタグ付けされたつぶやきとすべてのつぶやきの 2 種類の入力を使用した。

最後に、ツイートデータから取引量を予測できるかどうかを検証した。入力データとして、英語と日本語のすべてのツイートの TFIDF データ、およびその他の 4 つの特徴量 (いいねとリツイート数、そのユーザのフォロワー数、および前日からの BTC 価格の変化率) が使われた。

## 4 考察

表3は、本手法が他のメソッドよりも優れていることを示している。ここでは、本手法のパフォーマンスが「BTC の価格のデータのみ」を使うときのパフォーマンスより優れているという事実を焦点を当てる。

この結果は、我々の実験設定においてはインフルエンサーのつぶやきが暗号資産価格に影響を与えることを示している。

我々は他の機械学習法によっても価格を予測しようとしたが、これらの方法では図3に示すように、予測が

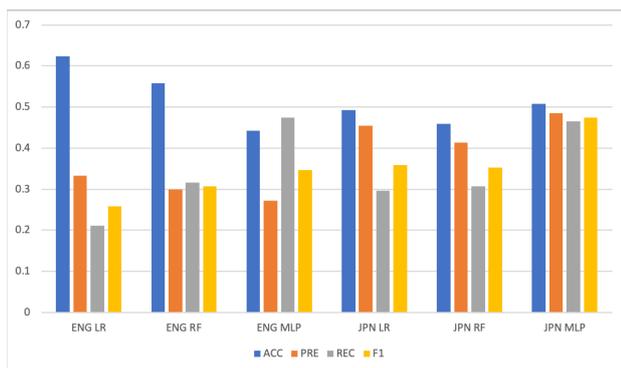


図 2: 価格の変化, 変化率 > 0.01

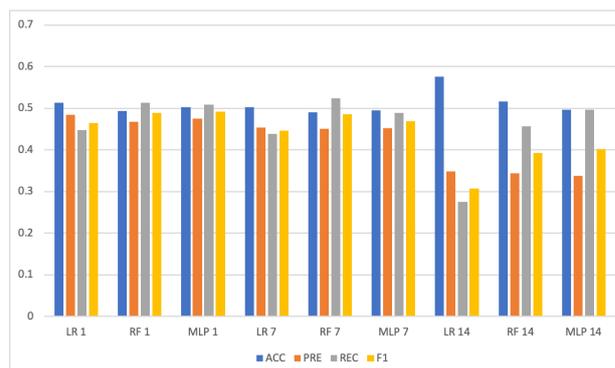


図 4: 取引量の変化, 入力: 英語

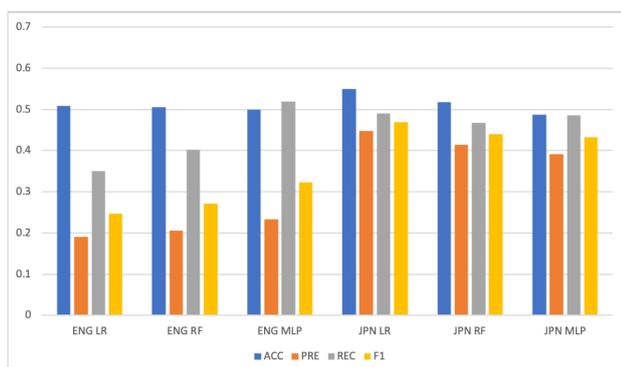


図 3: 価格の変化, 変化率 > 0.01, BTC または GEN とタグづけされているツイートのみ

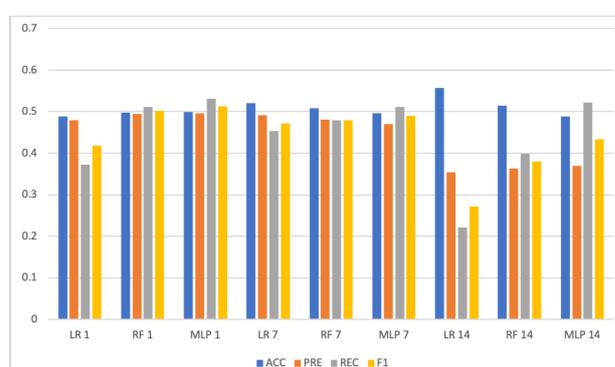


図 5: 取引量の変化, 入力: 日本語

可能であるという結果は得られなかった。結果として、この結果は、私たちの方法がツイートデータと暗号資産価格を効果的に使用できることを示している。すなわち、我々の方法は、暗号資産価格を予測するためにツイートデータを効果的に利用することができる。

図 2 と図 3 から、予測にタグ付きツイートを使用するとより良い結果が得られることがわかる。さらに、これらの結果では、日本語のつぶやきによる LR は他の方法よりも優れている。そのため、我々は LR を使用して手法を開発することにした。

図 4 と図 5 は、数量予測が言語に依存しないことを確認している。この結果から、ツイートを使って量を予測することは困難であることがわかる。そこで、ツイートを使って BTC の価格を予測する方法を開発した。

## 5 関連研究

Bollen らは、ツイートの気分がダウ工業平均株価の予測に役立つことを示した [Bollen 11]。彼らの研究では、予測に自己組織化ファジィニューラルネットワークを使用し、その結果、80%以上の精度で上昇と下降を予測することができた。Schumaker らは、金融ニュー

ス記事分析を用いて株価を予測するための機械学習アプローチを提案した [Schumaker 09]。彼らの研究は指標と株価を予測しているが、暗号資産価格は予測されていない。

金融テキストマイニングについては、Koppel らが会社の株価のパフォーマンスへの形に見える影響に従って会社のニュース記事を分類するための方法を提案した [Koppel 06]。Low らは移動概念を表す用語を抽出するためのシソーラスとして WordNet [Fellbaum 98] を使用する、semantic expectation-based knowledge extraction methodology (SEKE) [Low 01] を提案した。Ito らは金融テキストデータを視覚化するためのニューラルネットワークモデルを提案した [Ito 18]。さらに、彼らのニューラルネットワークモデルは単語感情とそのカテゴリを獲得することができる。Milea らは欧州中央銀行が発行した報告書から抽出したファジーな grammar fragments に基づいて MSCI ユーロ指数（上方、下方、または一定）を予測した [Milea 10]。

日本語の金融テキストマイニングに関しては、Sakai らが日本の業績に関する金融記事から業績要因を抽出する方法を提案した [Sakai 07]。彼らの方法は業績要因を抽出するための手がかりを使用しており、ブートストラップ法を使用して手がかりを自動的に集めること

ができる。Sakajiらは統計的手法を用いて新聞記事から経済動向を示す根拠表現を自動的に抽出する方法を提案した[Sakaji 08]。Kitamoriらは決算短信から業績予想と経済見通しを示す文を抽出して分類する方法を提案した[Kitamori 17]。分類方法は、半教師付きアプローチを使用することによるニューラルネットワークに基づいている。

これらの金融テキストマイニング研究は1つの言語のみを対象としている。対照的に、私たちの方法は複数の言語のつばやきを用いる。

## 6 まとめ

本稿では、BTC価格を予測する方法を提案した。この方法は、機械学習方法としてRFおよびLRを使用し、特徴としてツイートおよび暗号資産価格を使用する。特に、本手法の新規性は、RFの入力のために、LRの切片と係数を使用することである。この方法により、インフルエンサーのつばやきが暗号資産に影響を与えることが示された。さらに、我々は2つの言語でツイートを使用して実験し、暗号資産の量を予測することも試みた。

私たちの方法では、1%以上変化した場合のみを考えている。したがって、将来の研究として、この制限なしに暗号資産価格を予測する方法を見つけることが挙げられる。さらに、私たちの方法を使って仮想取引をシミュレートする事も考えられる。

## 参考文献

- [Bollen 11] Bollen, J., Mao, H., and Zeng, X.: Twitter mood predicts the stock market, *Journal of computational science*, Vol. 2, No. 1, pp. 1-8 (2011)
- [Breiman 01] Breiman, L.: Random Forest, *Machine Learning*, Vol. 45, No. 1, pp. 5-32 (2001)
- [Fellbaum 98] Fellbaum, C.: *WordNet: An Electronic Lexical Database*, The MIT Press (1998)
- [Hearst 98] Hearst, M., Dumais, S., Osuna, E., Platt, J., and Scholkopf, B.: Support Vector Machines, *IEEE Intelligent Systems and their applications*, Vol. 13, No. 4, pp. 18-28 (1998)
- [Ito 18] Ito, T., Sakaji, H., Izumi, K., Tsubouchi, K., and Yamashita, T.: GINN: gradient interpretable neural networks for visualizing financial texts, *International Journal of Data Science and Analytics* (2018)
- [Kitamori 17] Kitamori, S., Sakai, H., and Sakaji, H.: Extraction of sentences concerning business performance forecast and economic forecast from summaries of financial statements by deep learning, in *2017 IEEE Symposium Series on Computational Intelligence (SSCI)*, pp. 1-7 (2017)
- [Koppel 06] Koppel, M. and Shtrimberg, I.: *Good News or Bad News? Let the Market Decide*, pp. 297-301, Springer Netherlands, Dordrecht (2006)
- [Low 01] Low, B.-T., Chan, K., Choi, L.-L., Chin, M.-Y., and Lay, S.-L.: Semantic expectation-based causation knowledge extraction: A study on Hong Kong stock movement analysis, in *Pacific-Asia Conference on Knowledge Discovery and Data Mining (PAKDD)*, pp. 114-123 (2001)
- [Mikolov 13] Mikolov, T., Sutskever, I., Chen, K., Corrado, G. S., and Dean, J.: Distributed representations of words and phrases and their compositionality, in *Advances in neural information processing systems*, pp. 3111-3119 (2013)
- [Milea 10] Milea, V., Sharef, N. M., Almeida, R. J., Kaymak, U., and Frasinca, F.: Prediction of the MSCI EURO index based on fuzzy grammar fragments extracted from European Central Bank statements, in *2010 International Conference of Soft Computing and Pattern Recognition*, pp. 231-236 (2010)
- [Nakamoto 08] Nakamoto, S.: Bitcoin: A peer-to-peer electronic cash system (2008)
- [Sakai 07] Sakai, H. and Masuyama, S.: Extraction of Cause Information from Newspaper Articles Concerning Business Performance, in *Proc. of the 4th IFIP Conference on Artificial Intelligence Applications & Innovations (AIAI2007)*, pp. 205-212 (2007)
- [Sakaji 08] Sakaji, H., Sakai, H., and Masuyama, S.: Automatic Extraction of Basis Expressions That Indicate Economic Trends, in *Pacific-Asia Conference on Knowledge Discovery and Data Mining (PAKDD)*, pp. 977-984 (2008)
- [Schumaker 09] Schumaker, R. P. and Chen, H.: Textual Analysis of Stock Market Prediction Using Breaking Financial News: The AZFin Text System, *ACM Trans. Inf. Syst.*, Vol. 27, No. 2, pp. 12:1-12:19 (2009)

# LDA を用いた株式掲示板の投稿メッセージによる恐怖指数 上昇予測の提案

## Proposal of Prediction to Rise Volatility index based on Stock BBS using LDA

佐々木皓大<sup>1</sup> 諏訪博彦<sup>2</sup> 小川祐樹<sup>3</sup> 梅原英一<sup>1</sup> 山下達雄<sup>4</sup> 坪内孝太<sup>4</sup>

Kodai Sasaki<sup>1</sup>, Hirohiko Suwa<sup>2</sup>, Yuki Ogawa<sup>3</sup>, Eiichi Umehara<sup>1</sup>, Tatsuo Yamashita<sup>4</sup>, and Kota Tsubouchi<sup>4</sup>

<sup>1</sup> 東京都市大学 メディア情報学部

<sup>1</sup> Faculty of Informatics, Tokyo City University

<sup>2</sup> 奈良先端科学技術大学院大学 先端科学技術研究科

<sup>2</sup> Nara Institute of Science and Technology

<sup>3</sup> 立命館大学 情報理工学部

<sup>3</sup> Dep. of Information Science and Engineering, Ritsumeikan University

<sup>4</sup> Yahoo! JAPAN 研究所

<sup>4</sup> Yahoo! JAPAN Research

**Abstract:** There are many studies predicting a stock market using social media. Suwa et al. (2017) proposed a VI index prediction model. They assumed that changes sentiments of investors are topics change posted on social media. However, in their prediction model, the data to use verification is included in the data to use to develop their topic model. Hence, their model might be overfitting. Therefore, we propose a prediction model of VI index avoiding overfitting. We developed a program that applies new posting messages to topic models of a learning period. We created data for verification using this program. As a result, we found that a logistic regression using time series topics on the past seven trading days may predict a rise in the VI index.

## 1 はじめに

リーマンショックのような大きな相場変動の予測は、資産運用等において重要である。相場変動を表すリスク指数は、リターンの標準偏差である。リターンの標準偏差の指標として VI 指数が公表されており、VI 指数を予測することは重要である。

一方で、相場は投資家心理で動く。投資家心理が表現されるひとつの媒体としてソーシャルメディアがある。そこで本研究は、ソーシャルメディアの投稿内容を用いた VI 指数の上昇予測モデルを提案する。

## 2 先行研究

ソーシャルメディアに存在する情報を用いた株式市場の予測において、これまで数多くの研究が行われている。丸山ら[1]は、機械学習を用いて、Yahoo!

Finance 掲示板内の投稿数上位 50 銘柄の株式指標の予測を行った。彼らは、投稿数がボラティリティや出来高の先行指標であることを示した。諏訪ら[2]は、丸山ら[1]の結果を受け、市場全体を分析対象とすることを目的として、東証 1 部における投稿数及び強気指数によるポートフォリオを構築した。結果として、強気指数が市場全体で株価リターンと関係している可能性があることを示した。山内ら[3]は、時系列トピックモデルを用いて株式市場を予測するモデルを提案した。彼らは、時間情報を考慮したトピックモデルを用いて、時間情報を持ったニュース記事に対してトピックを割り当て、記事集合内のトピックの時間発展を推定した。推定したトピックの時系列変化と東証株価指数 (TOPIX) のボラティリティとの関連を調べ、ボラティリティ時系列モデルの改善に用いた。結果、彼らはトピックのスコアの有用性を示した。Suwa et al.[4]は、インターネット株式掲示板に基づく VI 指数予測手法を提案した。彼ら

は、ソーシャルメディアのメッセージをトピックモデルにより指標化し、VI 指数の予測に用いた。Random Forest によるモデルでは、適合率 0.66 を得た。しかし再現率が 0.06 と非常に低い結果であった。一方、ロジスティック回帰でのモデルでは、適合率 0.45 及び、再現率 0.45 を得た。よって彼らは予測モデルの有効性を示した。また、推定の際に有用な特徴量としてトピック別投稿率に加え、直近 7 取引日の VI 指数の日別変動、および投稿数が有効であることを示した。しかし予測精度が低い点や、新規投稿の分類に関する点を今後の課題とした。Sasaki et al.[5]は、Suwa et al.[4]の提案した VI 指数予測モデルの妥当性を検証することを目的として、ボラティリティトレーディングの売買シミュレーションを開発した。彼らは、オプション取引を用いて、予測モデルの上昇指示に基づきシミュレーションを行った結果、利益を出すことに成功した。これにより Suwa et al.[4]の予測モデルが有効な可能性があることを示した。彼らは、予測モデルの精度向上を課題とした。

そこで本研究は、Suwa et al. [4]での課題を解決し、予測モデルの構築を目指す。彼らの分析では、機械学習で推定する際に使用するトレーニングデータを作る過程で、テストデータとして使用した期間を含むトピックモデルが使われている。したがって彼らの提案手法では、過学習を起している。そこで我々は、過学習を回避する手法を提案するために、新規投稿をトピックモデルに適応させるプログラムを開発する。さらに、特徴量の見直しを行う。彼らは、特徴量を作る際に、各文書のトピックに閾値を設定した。閾値を超えたトピックのみを、各文書が持っているトピックとして定義した。本研究では、各文書のトピックに閾値を設定せず、全てのトピックを各文書が持っているトピックとして定義し特徴量を作成する。それにより過学習を回避した特徴量を作成する。作成した特徴量を機械学習に用いて、予測精度を測る。

### 3 構築手法

本章では、ソーシャルメディアの話題を用いて VI 指数を予測するモデルの構築手法について述べる。

#### 3.1 概要

構築手法の概要を図 1 に示す。ソーシャルメディアの話題は、Yahoo!JAPAN の株式掲示板から取得する。理由は、株取引について活発な投稿がなされている代表的な掲示板だからである。取得したメッセージから、投稿の内容を表す単語群を抽出するため

に、形態素解析を行う。形態素解析で得られた単語群から話題を抽出するために、LAD トピックモデルを用いてトピック分析を行う。これを基に、日別のトピック所属確率を集計する。日別のトピック所属確率を特徴量として、機械学習による VI 指数の上昇予測モデルを構築し評価する。

本研究では、分析対象データを前半と後半の大きく 2 つに分類する。前半のデータで、トピックモデルを作成し、VI 指数の上昇予測モデルを構築する。後半のデータは、前半のデータで作成したトピックモデルで、各文書に存在するトピック所属確率を推定し、予測モデルの検証に使用する。

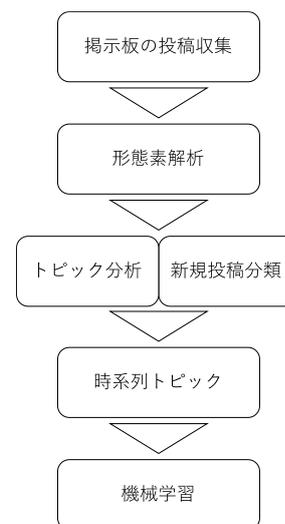


図 1 構築手法の概要

#### 3.2 分析対象

本研究で使用するデータは、Yahoo!JAPAN の株式掲示板内にある日経平均株価のスレッド内で投稿されたデータを用いた。分析期間は 2012 年 11 月 21 日から 2017 年 7 月 31 日である。この期間の投稿数は 4,738,275 件であった。このデータを用いて、共同研究先である Yahoo!JAPAN 研究所のサーバ内において解析した。

本研究は、日経平均 VI 指数の上昇を予測する。日経平均 VI 指数とは、投資家が日経平均株価の将来の変動をどのように想定しているかを表した指数である。指数値が高いほど、投資家が今後、相場が大きく変動すると見込んでいることを意味する。対象期間の VI 指数を図 2 に示す。

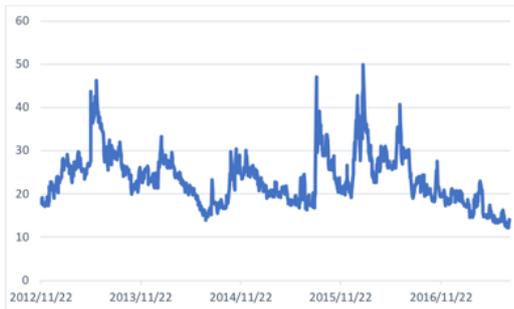


図 2 VI 指数

### 3.3 トピック分析

各投稿が、どのような話題を意味しているのかを判断するために、Blei et al.[6]の LDA トピックモデルを用いる。これは、「潜在的ディリクレ配分法」と呼ばれ、文書の確率的生成モデルである。各文書には潜在トピックがあると仮定し、統計的に共起しやすい単語の集合が生成される要因を、この潜在トピックという観測できない確率変数で定式化する。本研究では、全データを前半と後半とに分ける。前半の期間は、2012年11月21日から2015年6月21日とする。後半の期間は、2015年6月22日から2017年7月31日とする。

#### 3.3.1 時系列トピック

前半のデータを使用して、トピックモデルを作成する。トピックモデルは、以下の2種類からなる。

- 各文書におけるトピックの所属確率
- 各単語におけるトピックの生成確率

トピック数を100としてLDA分析をする。トピックの所属確率を求めるためのパラメータは、一般的なテキスト分類においてデフォルトの値として用いられている、 $\alpha=0.50$ 、 $\beta=0.10$ とする。1日に投稿された文書のトピック所属確率を全て足し、その日の総投稿数で割ることにより、日別のトピック所属確率を得る。この日別のトピック所属確率を時系列トピックとする。時系列トピックの推移が、その日に議論された話題の推移と考えられる。

#### 3.3.2 新規投稿の分類

我々は、新規投稿をトピックに分類するために、新規投稿分類プログラムを開発した。このプログラムを用いて、3.3.1節で求めた各単語におけるトピックの生成確率を利用して、後半のデータの各文書におけるトピックの所属確率を推定する。推定したトピックの所属確率から前半のデータと同様に、日別

のトピック所属確率を得て、時系列トピックを作成する。これを検証用のデータとして使用する。LDAは多項分布とディリクレ分布によって各データが生成されると仮定されている。しかし、本プログラムでは、一様分布によって生成されると仮定して推定を行う。

予備実験として、推定性能を比較するために、推定したいトピック未知の文書ファイルを、LDA分析に用いた文書ファイルで実行した。その結果、トピック番号の推定についてはトピック数10で7~8割、100で6割程度になった。同一のデータを使用しても、推定自体が確率分布を用いるために誤差が生じてしまうと考えられる。このため、文書の中でトピックの所属確率が1番高いトピックをその文書のトピックとして採用した。この点に関しては、今後の研究課題である。

### 3.4 機械学習

本研究では、対象期間の各日について、上昇・平穏の2クラスを定義し、代表的なアルゴリズムであるRandom Forestとロジスティック回帰を用いてモデルの構築をする。

#### 3.4.1 目的変数

VI指数の上昇について、当日のVI指数が過去7取引日の標準偏差より1.5倍以上離れた日を、VI指数が上昇する日と定義する。それ以外の日を平穏な日と定義する。対象期間である2012年11月から2017年7月までの1130取引日のうち、132日がこの定義に当てはまる日になった。Suwa et al. [4]の目的変数と変えた理由は、彼らの定義では、対象期間の全期間の日別変化の平均を用いているため、過去の情報だけでなく、未来の情報も含めてしまっているためである。本研究では、予測日より過去の情報のみを利用しているため、定義として妥当と考えられる。

#### 3.4.2 説明変数

本研究では、説明変数として、トピック投稿数及び時系列トピックとVI指数を基に13のモデルを作成した。トピック投稿数及び時系列トピックは以下の12種類である。

- トピック投稿数
- 時系列トピック
- トピック投稿数及び時系列トピックの前日差
- トピック投稿数及び時系列トピックの前日比
- 7取引日平均のトピック投稿数

- 7取引日平均の時系列トピック
- 当日のトピック投稿数（時系列トピック）と過去7取引日平均のトピック投稿数（時系列トピック）との差
- 当日のトピック投稿数（時系列トピック）と過去7取引日平均のトピック投稿数（時系列トピック）との比

総投稿数およびVI指数の日別変動は以下の12種類であるこの12種類を標準特微量と定義する。

- 総投稿数
- VI指数
- 総投稿数及びVI指数の前日差
- 総投稿数及びVI指数の前日比
- 7取引日平均の総投稿数
- 7取引日平均のVI指数
- 当日の総投稿数（VI指数）と過去7取引日平均の総投稿数（VI指数）との差
- 当日の総投稿数（VI指数）と過去7取引日平均の総投稿数（VI指数）との比

トピック投稿数及び時系列トピックと標準特微量を組み合わせて以下のモデルを作成する。

1. トピック投稿数+標準特微量
2. 時系列トピック+標準特微量
3. トピック投稿数の前日差+標準特微量
4. 時系列トピックの前日差+標準特微量
5. トピック投稿数の前日比+標準特微量
6. 時系列トピックの前日比+標準特微量
7. 7取引日平均のトピック投稿数+標準特微量
8. 7取引日平均の時系列トピック+標準特微量
9. 当日のトピック投稿数と過去7取引日平均のトピック投稿数との差+標準特微量
10. 当日の時系列トピックと過去7取引日平均の時系列トピックとの差+標準特微量
11. 当日のトピック投稿数と過去7取引日平均のトピック投稿数との比+標準特微量
12. 当日の時系列トピックと過去7取引日平均の時系列トピックとの比+標準特微量
13. 全ての特微量

これにより予測モデルを構築する。

## 4 分析結果

推定期間の2015年6月22日から2017年7月31日の中で取引日は518日だった。しかし、過去1週間の情報を用いるため、最初の7取引日のデータは棄却している。対象期間の511日中、上昇と定義した日は59日であった。予測精度の結果を表1に示す。

表1 予測精度の結果

	Random Forest			Logistic regression		
	適合率	再現率	F値	適合率	再現率	F値
1	0.87	0.89	0.84	0.81	0.71	0.75
2	0.81	0.88	0.83	0.79	0.18	0.16
3	0.84	0.88	0.83	0.79	0.81	0.80
4	0.87	0.89	0.84	0.82	0.83	0.82
5	0.78	0.88	0.83	0.79	0.81	0.80
6	0.90	0.89	0.84	0.81	0.80	0.80
7	0.86	0.89	0.84	0.79	0.70	0.74
8	0.85	0.88	0.84	0.73	0.14	0.09
9	0.86	0.89	0.84	0.80	0.82	0.81
10	0.85	0.88	0.85	0.83	0.77	0.80
11	0.90	0.89	0.84	0.80	0.83	0.81
12	0.87	0.89	0.85	0.83	0.75	0.78
13	0.90	0.89	0.84	0.81	0.72	0.76

Random Forest による最も高い適合率は、ケース6,11,13の0.90だった。しかしこれらの結果は、上昇日の予測結果ではない。上昇日の予測結果を表2に示す。

最も高い適合率は、Random Forest のケース6,11,13で1.00になった。しかし、再現率が2%~3%と非常に低い結果になった。一方で最も高い再現率は、ロジスティック回帰のケース2で0.92だった。しかし適合率が非常に低い結果となった。適合率が0.20以上かつ再現率が0.10以上のケースを抽出すると、Random Forest のケース2、ロジスティック回帰のケース4,10,12となり、その中で再現率が一番高い値で0.39だった。

表2 上昇日の予測結果

	Random Forest			Logistic regression		
	適合率	再現率	個数	適合率	再現率	個数
1	0.75	0.05	3/4	0.15	0.32	19/126
2	0.25	0.22	1/4	0.12	0.92	54/469
3	0.50	0.02	1/2	0.09	0.07	4/44
4	0.75	0.05	3/4	0.22	0.20	12/54
5	0.00	0.00	0/1	0.11	0.08	5/47
6	1.00	0.03	2/2	0.16	0.17	10/62
7	0.67	0.03	2/3	0.11	0.22	13/118
8	0.50	0.07	4/8	0.11	0.93	55/490
9	0.60	0.05	3/5	0.16	0.14	8/51
10	0.50	0.08	5/10	0.22	0.39	23/104
11	1.00	0.02	1/1	0.11	0.07	4/35
12	0.71	0.08	5/7	0.20	0.39	23/117
13	1.00	0.02	1/1	0.16	0.34	20/122

## 5 考察

機械学習によって VI 指数の予測を行なった結果、Random Forest では、ケース 6,11,13 で 1.00 になった。しかし、再現率が著しく低いため、本研究の提案手法としては採用しない。理由は、危機管理としては意味がある可能性があるが、今回はトレーディング目的のため再現率もある程度必要と考えるからである。その為、適合率が 0.20 以上かつ再現率が 0.10 以上のケースを抽出する。その結果 Random Forest のケース 2, ロジスティック回帰のケース 4,10,12 となり、その中で再現率が一番高い値は、ロジスティック回帰のケース 10,12 の 0.39 だった。本研究で採用するモデルは、ロジスティック回帰のケース 10 とする。本モデルの適合率及び再現率は、0.22, 0.39 となった。一方で本研究の上昇日の比率は、0.12(59/511)である。この結果から、予測モデルが有効な可能性がある。予測精度向上については今後の課題である。このモデルを使って、Sasaki et al.[5]の売買シミュレーション等において投資指示を出し、利益を出すことができるかの検証を行うことが今後の研究課題である。

本研究の結果と、Suwa et al.[4]の結果を比較すると、本研究のモデルの適合率及び再現率は低い結果となった。しかし、本研究は、過学習を回避しているため、この結果は妥当であると考えられる。

## 6 結論

本研究では、トピック分析を用いて VI 指数予測モデルの構築を行った。我々は、トピック分析の際に、新規投稿のトピックを分類するプログラムを開発した。さらに正解ラベルを過去情報のみで作成した。これにより完全に過去のデータのみで予測モデルを構築することが可能となった。このプログラムを用いて、機械学習によるクラス推定を行なった結果、適合率 0.22, 再現率 0.39 を得た。一方で、本研究の上昇日の比率は、0.12(59/511)である。この結果によって、過学習を回避したロジスティック回帰と過去 7 取引日の時系列トピックによる VI 指数予測モデルの利用可能性を見出した。恐怖指数と呼ばれる VI 指数を予測することにより、株価の大きな変動を予測できる。これにより、年金基金等が使う株式リスクモデルが構築できる。しかし、このモデルを実用化するためには、まだ数多くの課題が残っている。

## 7 今後の課題

今後の課題としては、第一に、予測精度の向上のため、特徴量や機械学習手法の見直しを行う必要が

ある。本研究では LDA トピック分析の結果を特徴量として使用した。しかし、学習期間に全く現れなかった話題で、推定期間よく議論された話題が出てきた場合に対応できない。そこで、Doc2Vec を用いる方法を検討する。Doc2Vec は、文書を低次元のベクトルに変更する手法である。新規投稿の分類も比較的容易である。さらに LDA との分類比較をした研究 [7]によると、Doc2Vec の分類精度の方が高いという結果を示している。機械学習手法の見直しとしては、特徴量の計算も機械学習に任せる手法を検討する。具体的には、時系列データを扱う必要がある為、機械学習に RNN(Recurrent Neural Network)の一種である LSTM(Long short-term memory)を用いて行うことが考えられる。第二に、今回の目的変数の定義では、VI 指数の過去 7 取引日の標準偏差を用いた。しかし「平穏」が続いているのにも関わらず、VI 指数の全体を見ると明らかに上昇している場合に対応できていない。ゆえに、正解ラベルの定義として「上昇」「徐々に上昇」「その他」の 3 ラベルとする方法が考えられる。「徐々に上昇」は連検定等を用いて定義する方法が考えられる。

## 謝辞

本研究の一部は科学研究費補助金基盤研究(C)(16K03820)の助成による。

## 参考文献

- [1] 丸山健, 梅原英一, 諏訪博彦, 太田敏澄. : インターネット株式掲示板の投稿内容と株式市場の関係, 証券アナリストジャーナル, Vol.46, No.11-12, pp.110-127, (2008)
- [2] 諏訪博彦, 梅原英一, 太田敏澄. : インターネット株式掲示板の投稿内容分析に基づくファクターモデル構築の可能性, 人工知能学会論文誌, Vol. 27, No.6, pp.376-383, (2012)
- [3] 山内海渡, 森本孝之. : 時系列トピックモデルを用いた株式市場の分析, 人工知能学会研究会 SIG-FIN-010-01, (2013)
- [4] Suwa, H, Ogawa, Y, Umehara, E, Kakiki, K, Yamashita, T, and Tsubouchi, K. : Develop Method to Predict the Increase in the Nikkei VI index, Proceedings of The 2nd International Workshop on Application of BigData for Computational Social Science in IEEE Bigdata 2017, (2017)
- [5] Sasaki, K, Hirose, Y, Umehara, E, Suwa, H, Ogawa, Y, Yamashita, T, and Tsubouchi, K. : Simulation of Volatility Trading using Nikkei Stock Index Option based on Stock

Bulletin Board, Proceedings of The Third International Workshop on Application of BigData for Computational Social Science in IEEE Bigdata 2018, (2018)

- [ 6 ] Blei, D, Ng, A, and Jordan, M. : Latent Dirichlet Allocation, Journal of Machine Learning Research, Vol.3, pp. 993-1022, (2003)
- [ 7 ] Andrew M, Dai, Christopher Olah, Quoc V. : Document Embedding with Paragraph Vectors, Proceedings of the NIPS Deep Learning Workshop, (2014)

# 金融機関のテキストデータに基づく企業の業績要因の抽出

Extraction of information on performance factors from financial institution texts

近藤 浩史<sup>1</sup> 大沼 俊輔<sup>1</sup> 中込 祐平<sup>2</sup> 遠藤 公志郎<sup>2</sup>

三橋 尚文<sup>2</sup> 佐藤 雪子<sup>2</sup> 酒井 浩之<sup>3</sup>

Hirofumi Kondo<sup>1</sup>, Shunsuke Onuma<sup>1</sup>, Yuhei Nakagome<sup>2</sup>, Koshiro Endo<sup>2</sup>

Naofumi Mitsuhashi<sup>2</sup>, Yukiko Sato<sup>2</sup> and Hiroyuki Sakai<sup>3</sup>

<sup>1</sup> 株式会社日本総合研究所

<sup>1</sup>The Japan Research Institute, Limited

<sup>2</sup> 株式会社三井住友銀行

<sup>2</sup> Sumitomo Mitsui Banking Corporation

<sup>3</sup> 成蹊大学

<sup>3</sup>Seikei University

**Abstract:** For financial institutions, it is important to monitor the performance and performance factors of corporate customers. Financial institutions accumulate large amounts of data to monitor customer information including their performance. It is relatively easy to extract information on performance from structured data, while it is difficult for non-structured data like text data. In this research, we tried to extract sentences that represent customer's performance factors from text data created by financial institutions. Our proposed method using deep learning extracts sentences similar to sentences prepared as correct examples in advance. Due to the difference in properties of text data, our method showed better performance than the prior research.

## 1. はじめに

金融機関にとって取引先企業の業績および業績要因を把握することは重要である。そのため、企業の公開情報（決算書など）の確認や、企業へのヒアリングを通して、業況の把握に努めている。その過程において、様々な資料が作成され、大量のデータが保管されている。

大量のデータから業績に関する情報を抽出する場合、構造化されたデータに対しては比較的容易である一方、テキストデータのような非構造化データに対しては難しいケースがある。一般に、テキストデータの検索ではキーワード検索が用いられるが、キーワードに一致した文が必ずしも業績を述べた文ではないこともある。そのため、予め大量のデータから業績文や業績要因文のみを抽出しておく必要がある。

そこで、本研究では金融機関の社員が企業との面談を通して作成した大量のテキストデータ（以下、企業内テキストと記載）から、業績文および業績要因文の抽出を試みる。

近年、テキストアナリティクス技術の進展により、テキストデータから企業の業績要因文等の抽出手法が研究されてきた。先行研究[1]では、決算短信 PDF から業績要因文を抽出する手法を提案し、良好な精度を得ている。その他、先行研究[2][3][4]のように、決算短信 PDF から原因・結果表現の抽出や、業績予測文の抽出も研究されている。また、先行研究[5]では有価証券報告書から因果関係文を抽出している。

先行研究では企業の公開情報を扱っているが、本研究では金融機関内にあるテキストデータを対象とする点が異なる。決算短信等は文書の性質上、記載すべき内容がある程度固定されており、文書内に業績を述べた文が存在する。一方、企業内テキストは内部文書につき、記載内容は多種多様である。そのため、先行研究の手法を企業内テキストに適用すると、業績要因文が高精度に取得できない恐れがある。

そこで、本研究では深層学習により業績要因文を抽出する手法（以下、深層学習による手法と記載）を提案する。本手法は予め決めた業績要因文の正解

データと類似する文を抽出する手法である。また、本研究では、比較のため先行研究[1]を再現した手法（以降、先行研究手法と記載することがある）も実装し、企業内テキストに対して適用する。

なお、深層学習による手法では、正解データの準備が必要であり、人手で準備するには手間がかかる。本研究では内閣府が公表する景気ウォッチャー調査[6]の景気判断理由集を活用し、正解データ作成の省力化にも取り組んだ。

結果として、文章の性質の違いから、先行研究[1]を再現して適用するよりも、深層学習による手法が良い性能で業績要因文を抽出できることが分かった。

## 2. 業績要因文の抽出手法

まず決算短信PDFから業績要因文を抽出する先行研究[1]の概略について述べ、次に深層学習による手法について述べる。

### 2. 1. 先行研究の概略

先行研究[1]は、文中の「手がかり表現」と「企業キーワード」に着目して、業績要因文を抽出する手法を提案している。

手がかり表現は、[1]によると「業績要因となる状況、状態、変化を表す用言的な表現」と定義される。

「堅調だった」「低迷した」等が具体例であり、業績要因文によく含まれる表現と解釈できる。

企業キーワードは、ある企業の決算短信PDFに含まれる名詞のうち、企業にとって重要な名詞のことである。[1]から具体例を挙げると、ソニーの企業キーワードとしては「液晶テレビ」が挙げられる。

企業キーワードは名詞のTF-IDFおよびエントロピーを基準にして抽出される。抽出基準を直感的に説明すると「他企業にはあまり出現しないが、ある企業にはよく出現し、かつ、当該企業の決算短信のそれぞれの文書に偏りなく出現する単語」となる。

業績要因文は、手がかり表現と企業キーワードの2つを用いて抽出される。まず手がかり表現を含む文を検索し、手がかり表現に係る節に企業キーワードを含む文を業績要因文として抽出する。[1]によると、ソニーの例では、企業キーワード「液晶テレビ」、手がかり表現「減少した」を元に、「この大幅な減収は、主に液晶テレビの販売台数が大幅に減少したことによるものです」という業績要因文が取得される。

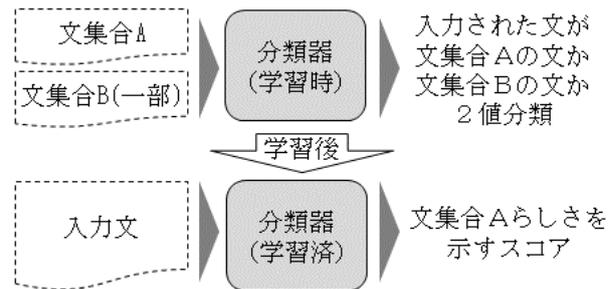


図1：分類器の構築

## 2. 2. 深層学習による手法

### 2. 2. 1 対象データの絞り込み

先行研究[1]を参考に、深層学習による手法においても「手がかり表現」を含む文を対象に業績要因文を抽出する。分析対象となる文書の性質が変わったとしても、業績要因文には「堅調だった」といった表現がよく含まれると考えられるためである。

手がかり表現の抽出手法は先行研究[1]と同様とし、手がかり表現を文中に含む文を抽出することで対象データを絞り込む。

### 2. 2. 2 業績要因文の抽出器の構築

抽出器は文集合Aと文集合Bが与えられたときに、文集合Aの類似文を文集合Bから抽出するモデルである。抽出器は以下に示す4つのテキスト分類器をアンサンブルして構成する。

#### ① TF-IDF/LR モデル

学習で使用した文に含まれる単語のTF-IDFを特徴量として、ロジスティック回帰で文章を分類するモデル。

#### ② CNN/NN モデル

先行研究[7]をベースとしたモデル。

#### ③ 双方向LSTM/NN モデル

双方向LSTM（以降、BiLSTMと記載）とニューラルネットワークを組み合わせたモデル。

#### ④ SWEM/LR モデル

先行研究[8]にSWEM-concatと記載されたモデル。SWEM-concatの特徴量を文の特徴量として、ロジスティック回帰で文章を分類するモデル。

以上4つの分類器を使用し、抽出器を以下①②の手順で構築する。

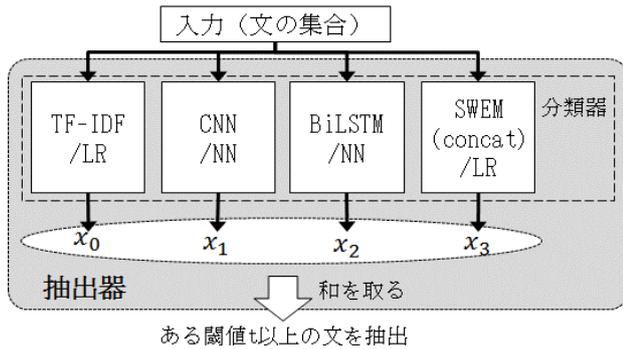


図 2 : 抽出器の概略図

### ① 各分類器の学習 (図 1)

各分類器は入力文の特徴量を生成し、入力文が文集合 A の文か、文集合 B の文かを 2 値分類する。各分類器は同じ学習データから、独立に学習させる。学習済み分類器は入力文の文集合 A の文らしさを示すスコアを出力する。

なお、各分類器の学習時には、文集合 B の全体を学習データとするのではなく、文集合 B からサンプリングした文集合 B の一部を用いる。これは、各文集合に含まれる文数の偏りを小さくするためである。

### ② 抽出器の構築 (図 2)

学習済みの分類器をアンサンブルする。抽出器は入力された文に対して、各分類器が出力する文集合 A の文らしさを示すスコアの和を集計し、予め決めた閾値よりも大きな値の文を抽出して出力する。

このように構築した抽出器に対して、文集合 B の全文を入力し、抽出器から出力された文は、文集合 A に似た文章と言うことができる。

本研究では文集合 A が抽出すべき業績要因文の正解データで、文集合 B が企業内テキスト (手がかり表現含む) となる。

## 2. 2. 3 正解データの作成

企業内テキストから正解データを多数作成するためには、大量の文を読む必要があり、手間がかかる。

そこで、内閣府が公表する景気ウォッチャー調査の景気判断理由集を活用し、以下①②の手順で正解データを作成した。景気判断理由集を使用した理由は、景気判断理由集の文に、企業の業績要因文と似た文が存在するからである。例えば「観光客が増えているが、お盆時期の天候不順の影響で見込みほど売上が伸びなかった。」といった文が含まれている。

なお、企業内テキストのうち、景気ウォッチャーの景気判断理由集の文と類似する文を景気ウォッチャー類似文と記載する。

### ① 景気ウォッチャー類似文の抽出

前節で説明した抽出器の仕組みを用いて、景気ウォッチャー類似文を抽出した。具体的には、前節で説明した文集合 A を景気ウォッチャー調査の景気理由判断集の文、文集合 B を企業内テキストとして抽出器を構築した。

### ② 景気ウォッチャー類似文に対するラベル付け

景気ウォッチャー類似文は厳密には業績要因文ではない。そのため、抽出済みの景気ウォッチャー類似文の各文に対して、業績要因文の正解データとすかどうかをラベル付けした。

景気ウォッチャー類似文 (業績要因文に類似する文) に対してのみラベル付けを実施することで、正解データの作成が省力化された。

## 3. 実装

### 3. 1. テキストの前処理

企業内テキストは 2010 年 1 月～2018 年 8 月に作成されている。企業内テキストは複数の文書から成り、文書をさらに文に分割して使用する。文を単語に分割する際には、MeCab を使用し、辞書として mecab-ipadic-NEologd [9] と独自の金融用語辞書を組み合わせ使用した。また、意味ある文を構成しないと想定される短文 (動詞、名詞、形容詞の合計が 5 単語以下の文) は事前に除去した。このようにして全体で約 5,000 万件の文を得た。以降、前処理済みの企業内テキストを抽出対象文と呼ぶ。

本研究で使用した、景気ウォッチャーの景気判断理由集は 2013 年 1 月～2018 年 11 月に公開されたデータである。企業内テキストと同様に前処理を実施するが、短文は除去していない。以降、前処理済みの景気ウォッチャー調査の景気判断理由集の文を調査文と呼ぶ。

### 3. 2. 先行研究の手法

手がかり表現は、[10] を Python に移植したプログラムを元にして、調査文から取得した。調査文を使用した理由は、前述のとおり業績要因文に近い表現で記載されているからである。

景気判断理由集から手がかり表現を抽出すると、不適切と考えられる手がかり表現が抽出された。例えば「多い」「少ない」等の一般的な形容詞が挙げられる。人手で不適切な手がかり表現を除去し、結果として 226 件の手がかり表現を得た。

キーワード抽出および業績要因文の抽出は [1] を元に実装した。本実装を用いて抽出対象文から業績要因文を得た。

### 3. 3. 深層学習による手法

#### 3. 3. 1 対象データの絞り込み

抽出対象文から手がかり表現を含む文を絞り込む際には、3.2 節で述べた先行研究と同じ手がかり表現を用いた。抽出対象文から手がかり表現を含む文を抽出したところ、約 170 万件の文を得た。

#### 3. 3. 2 正解データの作成

2.2.3 節で述べた正解データ作成の際には、調査文および抽出対象文から、それぞれ 3 万文(計 6 万文)をランダムにサンプリングして、景気ウォッチャー類似文の抽出器を構築した。

取得した景気ウォッチャー類似文のうち、24,057 文に対して人手でラベル付けを行い、業績要因文 16,568 文と非業績要因文 7,489 文を得た。

#### 3. 3. 3 抽出器の構築

業績要因文の抽出器の構築では、表 1 に示すデータを使用した。

人手でラベル付けしたデータに加えて、調査文および抽出対象文からランダムにサンプリングした文を追加した。調査文と抽出対象文を追加する理由は、業績要因文と非業績要因文の特徴を幅広くモデルが学習できるようにするためである。

文集合 A には抽出すべき業績要因文の正解データを設定するため、人手でラベル付けした業績要因文と調査文を加えた。また、文集合 B には非業績要因文を設定するため、人手でラベル付けした非業績要因文と抽出対象文を加えた。なお、文集合 B に加える抽出対象文はランダムにサンプリングするため、業績要因文を含む可能性があるが、件数が少ないと想定されるため問題にはならない。

構築した抽出器を用いて、抽出対象文(手がかり表現含む)から業績要因文を抽出した。なお、抽出器の閾値は 1.0 とした。

表 1 : 抽出器の構築に使用したデータ件数

文集合	人手でラベル付け	ランダムに追加	合計
A	16,568	15,875 (※1)	32,443
B	7,488	24,390 (※2)	31,878

※1 : 調査文から取得

※2 : 抽出対象文から取得

## 4. 評価

### 4. 1. 抽出精度の評価

抽出した業績要因文から 1,000 文をランダムにサンプリングし、人手で業績要因文であるかどうかをラベル付けして抽出精度を評価する。ラベル付けは「業績要因文」「業績関連文」「間違い」の 3 値分類とした。なお、業績関連文とは「猛暑の影響で客足が遠のいている」といった遠回しに業績を述べた文を示す。

表 2 に深層学習による手法と先行研究手法の抽出精度を記載した。深層学習による手法の精度は 65.3% (業績関連文と合わせると 85.6%) であり、比較的高い精度で業績要因文を抽出できた。

表 2 : ラベル付け結果の件数と割合

	深層学習による手法	先行研究手法
業績要因文	653 (65.3%)	284 (28.4%)
業績関連文	203 (20.3%)	108 (10.8%)
間違い	144 (14.4%)	608 (60.8%)

### 4. 2. 再現率の評価

再現率は、ランダムにサンプリングした 10 社を元に評価する。本来は全データを元に評価すべきだが、業績要因文の全量を把握することが困難なためサンプリング評価する。サンプリングした 10 社の抽出対象文(手がかり表現含む)および抽出した業績要因文を、人手でラベル付けして評価した。ラベル付けは精度評価と同様に 3 値分類とした。

表 3 はサンプリングした 10 社において、再現率・精度・F 値を算出した結果である。深層学習による手法では高い再現率を達成している。

表 3 : サンプリングした 10 社に対する  
再現率・精度・F 値の評価

	業績要因文のみ		業績要因文 + 業績関連文	
	先行研究手法	深層学習による手法	先行研究手法	深層学習による手法
再現率	0.72	0.92	0.68	0.86
精度	0.33	0.55	0.48	0.80
F 値	0.45	0.69	0.56	0.83

### 4. 3. 考察

再現率、精度ともに深層学習による手法が先行研究よりも高い性能を発揮している。ただし、表3によると、先行研究手法も、精度は0.33と低いが、再現率は0.72と比較的良好な結果となっている。

この原因は企業キーワードの取得にあると考える。企業内テキストは、決算短信PDFとは異なり、企業の業績を述べた文だけでなく、様々なトピックを扱っている。そのため、企業の商品名や部門名が企業キーワードとして抽出されるだけでなく、企業内テキストに良く記載されている金融商品に関する事項・書類名・地名なども抽出されやすい。

したがって、抽出した企業キーワードの中には業績要因文に入るべきキーワードも含んでいるために、再現率は比較的高くなるが、全く関係ないキーワードも含むため精度が低下すると考えられる。

一方、深層学習による手法は、企業内テキストの文の特徴が、予め準備した正解データの文の特徴と類似する文を抽出するため、企業キーワードに依存せずに業績要因文を抽出できたと考える。

### 5. まとめ

本研究では企業内テキストデータを対象に、深層学習により業績要因文を抽出する手法を提案した。企業キーワードに着目して業績要因文を抽出する先行研究よりも、提案手法が良い性能を示すことが分かった。これは企業内テキストが業績に関する文だけでなく、様々なトピックを使った文が多く含まれるためである。

本研究が提案した深層学習による手法は企業キーワードによらず業績要因文を抽出できるが、正解となる業績要因文の作成に手間がかかることが欠点と考えられる。本研究では、景気ウォッチャー調査の景気理由判断集を活用することで、正解データの作成も大幅に省力化することができた。

今後の課題としては更なる性能向上のために抽出モデルを工夫することなどが挙げられる。

### 参考文献

- [1] 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)
- [2] 坂地 泰紀, 酒井 浩之, 増山 繁 : 決算短信 PDF からの原因・結果表現の抽出, 電子情報通信学会論文誌 D, vol.J98-D, no.5, pp.811-822, (2015)
- [3] 北森 詩織, 酒井 浩之, 坂地 泰紀 : 決算短信 PDF からの業績予測文の抽出, 電子情報通信学会論文誌 D, vol.J100-D, no.2, pp.150-161, (2017)
- [4] 酒井 浩之, 坂地 泰紀, 室野 莉沙, 北島 良三, ベネット ジェイスン : 意外性のある原因・結果表現の決算短信からの抽出, 第 32 回人工知能学会全国大会, (2018)
- [5] 佐藤 史仁, 佐久間 洋明, 小寺 俊哉, 田中 良典, 坂地 泰紀, 和泉 潔 : 有価証券報告書からの因果関係文の抽出, 第 32 回人工知能学会全国大会, (2018)
- [6] 内閣府 景気ウォッチャー調査  
[https://www5.cao.go.jp/keizai3/watcher/watcher\\_menu.html](https://www5.cao.go.jp/keizai3/watcher/watcher_menu.html) (2019/1/28 アクセス)
- [7] Yoon Kim : Convolutional Neural Networks for Sentence Classification, EMNLP2014, (2014)
- [8] Dinghan Shen, Guoyin Wang, Wenlin Wang, Martin Renqiang Min, Qinliang Su, Yizhe Zhang, Chunyuan Li, Ricardo Henao and Lawrence Carin : Baseline Needs More Love: On Simple Word-Embedding-Based Models and Associated Pooling Mechanisms, ACL2018, (2018)
- [9] 佐藤敏紀, 橋本泰一, 奥村学 : 単語分かち書き辞書 mecab-ipadic-NEologd の実装と情報検索における効果的な使用方法の検討, 言語処理学会第 23 回年次大会, (2017)
- [10] 手がかり表現自動獲得プログラム (CLue Phrases Extraction Software),  
<https://www.ci.seikei.ac.jp/sakai/clupes.html> (2019/01/28 アクセス)

# アナリストレポートを用いた中長期株価動向推定

## Stock Price Analysis in Mid-to-long Term Using Analyst Reports

堅木 聖也<sup>1\*</sup> 坂地 泰紀<sup>1</sup> 和泉 潔<sup>1</sup> 石川 康<sup>2</sup> 笠岡 恒平<sup>2</sup>  
Toshiya Katagi<sup>1</sup> Hiroki Sakaji<sup>1</sup> Kiyoshi Izumi<sup>1</sup> Yasushi Ishikawa<sup>2</sup> Kohei Kasaoka<sup>2</sup>

<sup>1</sup> 東京大学大学院工学系研究科

<sup>1</sup> School of Engineering, The University of Tokyo

<sup>2</sup> 日興アセットマネジメント株式会社

<sup>2</sup> Nikko Asset Management Co., Ltd.

**Abstract:** In this paper, we propose a methodology to forecast the direction and extent of volatility in mid-to-long term excess return of stock price by applying natural language processing and neural networks on the context of analyst reports. Analyst reports are prepared by analysts in research department in stock brokerage firms and we consider the content of reports include useful information to forecast movements in stock prices. First, our method extracts opinion sentences from analyst reports, while the remaining parts correspond to non-opinion sentences. Second, our method predicts stock price movements by inputting opinion sentences and non-opinion sentences to neural networks separately.

## 1 はじめに

現在、日本における株式投資の重要性が拡大している。日本取引所グループ(JPX)の調査レポート[日本18]によると、日本における個人株主数は右肩上がりが増加しており、特に2017年度の個人株主数は、前年度比162万人増加して5,129万人となり、初めて5千万人を超えることとなった。

この流れは更に加速すると考えられる。直近ではアベノミクスの効果、及び2020年に予定されているオリンピックの効果により、多くの企業の株価は増加傾向にあり、実際、東京証券取引所の第一部上場銘柄を対象にした指数である、東証株価指数(TOPIX)も右肩上がりとなっている。その結果として、日本株の魅力度は増大している。

投資にあたって、投資家達は、対象企業に対するあらゆる情報を調べることになる。しかし、その情報源は多角化しており、情報収集は困難を極める。企業のホームページを見ると、IR(Investor Relations)のページには決算短信、決算説明会資料、アニュアルレポート、有価証券報告書といった資料が乱列しており、検索エンジンで社名を検索すれば、多くのニュースがヒットし、株価の掲示板を見ると、過去の株価推移や投資家達の意見が存在する。さらに近年ではTwitterやFacebook、InstagramといったSNS(ソーシャルネットワークサー

ビス)における人々のコメントも投資家のセンチメントを反映していると言えよう。実際、迫村ら[迫村13]の研究では、SNSの1つであるTwitterの投稿における、強気比率や偏りが、その後の株式リターンに反映されている可能性が示されている。

このように、情報化が進んだ昨今では、株式投資という行為一つを取っても、参照すべき情報が溢れており、各投資家達にとっては、その取捨選択が困難を極めている。この状況下でより注目を集めているのがアナリストレポートである。アナリストレポートはその名前の通りアナリストが個別企業に対して書くレポートであり、金融のプロフェッショナルが、公表資料やニュース、会社取材、株価バリュエーション、マクロ経済動向などを全て考慮した上で、事実関係を整理し、自身の評価を下したものであるため、各情報源の上位互換とみなすことができるであろう。そこで本研究では、アナリストレポートの本文を解析し、株価動向を予測することを目指す。特に、株価の動向において特に重要となる、株価のボラティリティの大小及び株価の対市場超過リターンの符号の予測を今回は行う。更に、本文の中でも、文章を2通りに分類することを考える。アナリストレポートには、アナリストが集約した客観的事実を示す文章(非意見文)と、それに基づいてアナリスト自身がどう考えたのかを表す文章(意見文)が存在する。これらの内、意見文は市場が瞬時には織り込み難いアナリストの意思を反映するため、株価ボラティリティの大小に対する予見性を持ち、残った非

\*連絡先：東京大学大学院工学系研究科  
E-mail: m2017tkatagi@socsim.org

意見文は客観事実の中から株価形成に重要だとアナリストが判断した事象を多く含むため、超過リターンの正負に対する予見性を持つという仮説を持った。この仮説を検証し、アナリストレポートと実際の株価変動の関係性を示すことを本研究の目的とする。

加えて、リターンの方向に関しては、Bollenら [Bollen 11] の先行研究において、極性値の情報を利用することで成果を挙げていることから、極性値の情報をも用いることで更なる性能の向上を目指した。

そして本研究は、実際に株式投資を行われている資産運用会社との共同研究となっているため、将来的に資産運用への応用を目指すことを念頭に置く。

## 2 全体の流れとデータセットの作成

本研究では、意見文の判別、株価動向の推定、の2段階で実験を行った。

### 2.1 意見文の判別のデータセットの作成

2017年に発行された10,100本のアナリストレポートからランダムに100本を抽出した。さらにこの中からボディに相当する部分のみを抽出した。合計2,213文に対して、手動で意見文/非意見文のラベリングを行った。意見文はレーティングや企業の売上や純利益の次年度の予測値といったアナリスト自身の予測や、今後企業が取るべき施策、現在の業績となった背景などといった内容が含まれている文を指しているのに対し、非意見文は企業の過去の業績値といった事実に関する文を指している。その結果、意見文と判断されたものは1,025文となった。

### 2.2 株価動向の推定のデータセットの作成

2017年に発行されたアナリストレポートの各レポートの発行日、本文を取得した。また、発行日と発行日から2週間後の株価及び、TOPIXを取得し、この期間でのTOPIXに対する超過リターンを得た。超過リターンを採用したのは、2017年が長期化した景気回復局面にあり、単純なリターンを用いると正のリターンに分布が偏ってしまうからだ。さらにベンチマークに対する相対パフォーマンスにより運用能力を評価される機関投資家にとっては、対市場超過リターンに対する予見性が重要であるという背景もある。分類の結果、2,041個のデータを入手した。超過リターンの正負の予測のために、超過リターンの正のものに1、負のものに0とラベリングを行った。また、ボラティリティの予測のために、超過リターンの絶対値が2.745%より小さいものに0、大きいものに、0とラベリングを行った。こ

の2.745%は、レポートがちょうど半分に分割される閾値となっている。

## 3 意見文の判別

第1段階である意見文の判別に関しては、MLP(Multilayer Perceptron), Bidirectional LSTM(Bidirectional Long short-term memory), SVM(Support Vector Machine), ランダムフォレストを用いて実験を行った。

MLP, SVM, ランダムフォレストについては、使用するアナリストレポートに含まれる単語を One hot 表現したベクトルを入力データとした。利用されている単語は5,126個であるので、ベクトルの次元も5,126次元となった。

また、Bidirectional LSTMへの入力データは、Word2vecを用いて作成したベクトルとした。コーパスはアナリストレポートを使用した。その結果、金融に特有な単語を意味を保持したままベクトル化することができた。Bidirectional LSTM層から得られた隠れ状態ベクトルはMLP層へと伝播され、最終層でソフトマックス関数を用いて、意見文/非意見文となる確率を出力させた。モデルの様子を図1に示した。

それぞれの手法による結果は、表1のようになった。なお、結果においては意見文であるものを正としている。表1において、PreとはPrecisionを意味する。表

表 1: MLP と LSTM による意見文の判別の結果

手法	Pre	Recall	F1
MLP	0.733	0.827	0.777
Bidirectional LSTM	0.846	0.772	0.808
SVM	0.790	0.618	0.694
ランダムフォレスト	0.757	0.643	0.695

1から、Bidirectional LSTMが最もF1が高いことが分かる。この理由は、入力データにあると考えられる。今回は単語の分散表現を入力させたが、単語の分散表現はすでにアナリストレポートを使って事前学習させたものとなっている。すなわち、アナリストレポートに出現する単語の順や位置関係に関わる情報がこのモデルの学習前からインプットされていることになる。

以後の実験において、意見文を抽出するものに関しては、このBidirectional LSTMの学習モデルを使って抽出することとした。

## 4 株価動向の推定

株式投資を行う際に、投資家が意識するポイントは2つある。1つ目は超過リターンの方向が正か負のどちら

かであるかという点であり、もう1点は、株価の変動が大きいかどうかという点である。これらの情報を組み合わせることで、各銘柄の動きをアナリストレポートのレーティングのように、Strong buy, Buy, Sell, Strong Sell と分類でき、株の取引に応用されることが期待される。そこで、本研究では、この2点、超過リターンの正負、超過リターンのボラティリティの大小に対する判別を行った。

手法としては、意見文の判別において成果を上げた Bidirectional LSTM を用いた。Bidirectional LSTM への入力の仕方については、意見文と非意見文がそれぞれボラティリティと方向性に寄与するのではないかと、という仮説の下、以下の4つを試行した。

- 全文を入力
- 意見文のみを入力
- 非意見文のみを入力
- 意見文と非意見文を分割した後、別々に入力

全文を入力、意見文のみを入力、非意見文のみを入力の方法に関しては、図2のネットワークを用いた。

また、意見文と非意見文を分割した後、別々に入力する場合に関しては、図3のネットワークを用いた。上記3つと異なり、2つの Bidirectional LSTM を用いているため、隠れ状態ベクトルの次元は合計160次元として、MLP層に入力した。

また、リターンの方向性に関しては、極性値の利用を検討した。極性値の取得方法については、東京工業大学高村大也教授の PN Table<sup>1</sup>及び、金融に特化した極性辞書 [伊藤 17] の利用を検討した。利用辞書選定のために、意見文の判別の際に用いた、2,213文に含まれる意見文に手動で、Positive かどうかをラベリングし、辞書によって判別させた。判別は文に含まれる単語の極性を辞書を参照し獲得した後、平均をとることで行った。その際、極性値が正のものを Positive、負のものを Negative と定義した。これらから Positive を正として、Precision, Recall, F1 を計算すると表2のようになった。これより、3指標においてスコアが勝った

表 2: 極性辞書を使用した極性判別の結果

使用辞書	Pre	Recall	F1
一般辞書	0.556	0.009	0.018
金融特化辞書	0.640	0.739	0.686

金融特化辞書を採用することにした。このような差が

<sup>1</sup>[http://www.lr.pi.titech.ac.jp/~takamura/pndic\\_ja.html](http://www.lr.pi.titech.ac.jp/~takamura/pndic_ja.html)

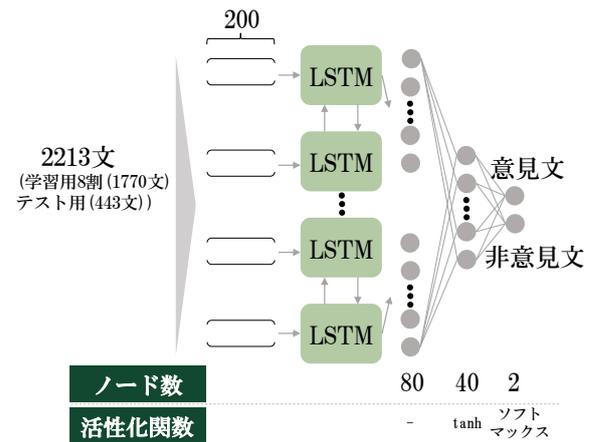


図 1: 意見文判別のモデル

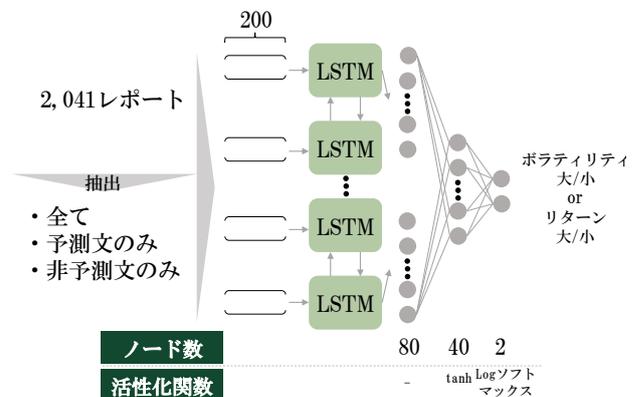


図 2: 全文・意見文のみ・非意見文のみを入力する場合のモデル

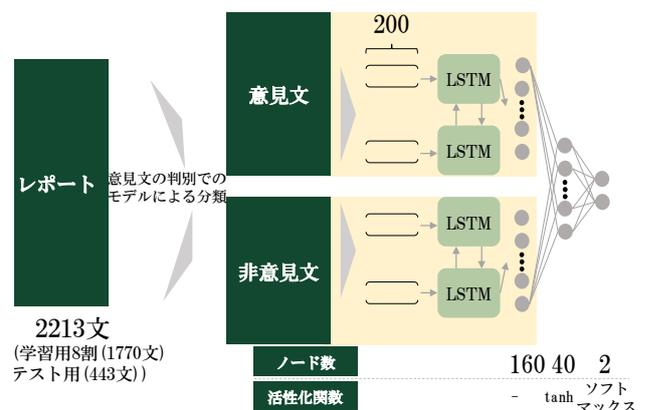


図 3: 意見文と非意見文を分割した後、別々に入力する場合のモデル

出た理由は、そもそも一般辞書の極性が負に偏っていたことや、金融特化辞書では「自社株買い」のような一般的ではないが、極性に大きく影響する単語までスコアが振られていたことが挙げられる。金融特化辞書により獲得された極性値の入力方法は、図4に示した2種類を検討した。一つは左図に示した、文章の極性値を入力する方法である。文章に含まれる各単語の極性値を平均した後に、MLP層に入力した。もう一方は右図に示した、各単語の極性値を入力する方法である。各単語の極性値を入力として用いている Word2vec のベクトルに追加した後に Bidirectional LSTM 層に入力した。

さらに、今回はアナリストレポートの本文という同一の入力から、超過リターンの方向性とボラティリティという複数の対象を予測することから、マルチタスク学習 [Caruana 97] の利用を試みた。図5に示したように、同一の入力とネットワークにより、同時に超過リターンの方向とボラティリティを推定することを目指した。なお、極性値を用いた推定とマルチタスク学習を用いた推定では、入力テキストは文章全体とした。

## 5 結果と考察

以下、各実験において、リターンが正の時、ボラティリティが大の時を正とした場合の、各評価指標を示した。

### 5.1 超過リターンの正負の推定

これより、F1 を比較すると、非意見文のみを入力→意見文と非意見文を別々に入力→全文→意見文のみを入力、の順で性能が良いことが分かる。

### 5.2 超過リターンのボラティリティの推定

これより、F1 を比較すると、意見文のみを入力→意見文と非意見文を別々に入力→全文→非意見文のみを入力、の順で性能が良いことが分かる。

以上2つのリターンの方向性の実験とボラティリティの大きさの実験から、リターンの方向性の推定には非意見文が、ボラティリティの大きさの推定には意見文が重要となっていることが確認された。このような結果になった理由として、市場の投資家の投資スタイルの観点から検討をする。株のトレーディングにおいては、リスクを取り、短期間で売買を行う短期トレーディングと、リスクを減らし、長期間でトレーディングを行う長期トレーディングが存在する。前者を行う投資家は比較的少額の金額を日々取引していくので、日々の株価のトレンドを形成していくと考えられる。後者は、資産運用会社が取手法であり、取引頻度は小さ

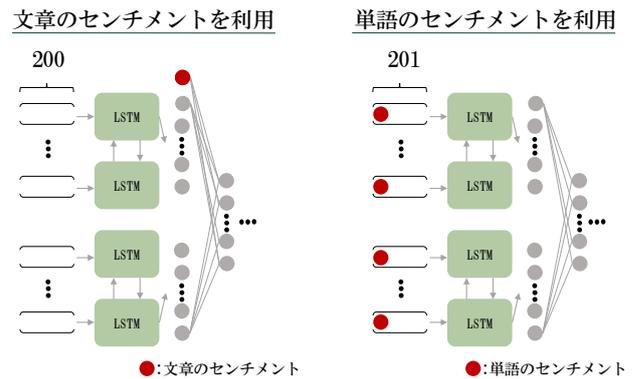


図 4: センチメントの Bidirectional LSTM への入力方法

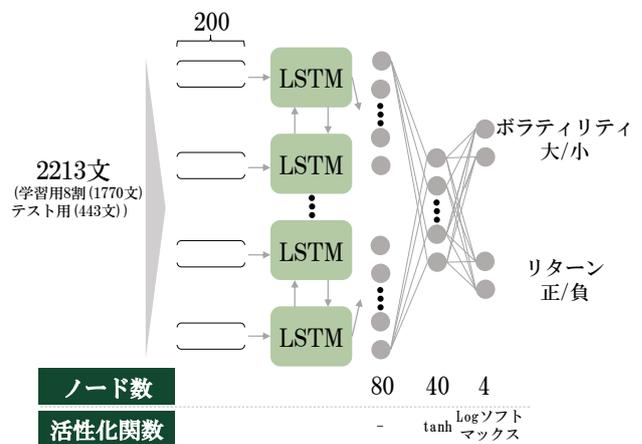


図 5: マルチタスク学習のネットワーク

表 3: 超過リターンの方向の判別の評価指標

入力の種類	Pre	Recall	F1
全文	0.564	0.591	0.577
予測文のみ	0.490	0.517	0.503
非予測文のみ	0.614	0.659	0.636
予測文と非予測文	0.589	0.603	0.596

表 4: 極性辞書を使用したボラティリティ判別の結果

入力の種類	Pre	Recall	F1
全文	0.552	0.520	0.538
意見文のみ	0.567	0.587	0.577
非意見文のみ	0.532	0.509	0.520
意見文と非意見文	0.553	0.553	0.553

いが、取引額が大きいと、市場にインパクトを与えやすいと考えられる。

ここで、それぞれの投資家が参考にする情報を考える。短期トレーディングを行う投資家は、短期保有を前提とするため、将来的な業績予測よりも、すでに公開されている事実や、直近での株価の変動の様子を参考に投資判断を下すと考えられる。一方で長期トレーディングを行う投資家は、長期的な保有を前提とするため、まだ確定しない将来の業績に目を向ける。そのような情報が盛り込まれているのがアナリストレポートであるが、アナリストレポートは膨大な量が発行されているため、全てを一言一句読み込むということは時間的に難しい。実際の運用担当者は、アナリストにより違いが出易い意見文のみを精読する場合も多い。これらをまとめると、日々のトレンドを作っていく短期トレーディングを行う投資家は既に公開された事実を考慮し取引を行うのに対し、取引額が大きいと株価の変動を引き起こしやすい長期トレーディングを行う投資家はアナリストの意見文のように市場に十分織り込まれていない情報を考慮し取引を行うことになる。そのために、超過リターンのボラティリティの大小はアナリストレポートの意見文の情報から予測され、超過リターンの方向性はアナリストレポートの非意見文の情報から予測されたのだと考えられる。

### 5.3 極性値を用いた推定

表 5: 極性値を利用したリターンの方向性推定の評価指標

使用する極性辞書	Pre	Recall	F1
文章全体	0.573	0.607	0.590
単語	0.556	0.584	0.570

極性値を用いない場合の結果である表 3 の全文と比較すると、文章全体の極性値を利用した場合は 3 つの指標全てにおいて改善がみられ、一方で単語のセンチメントを利用した場合は、3 つの指標全てにおいて悪化していることが分かる。

単語の極性値を利用した場合で悪化した理由として、単語の辞書に含まれていない単語の存在があげられる。今回の実験で使ったレポートに含まれる単語数は 693,562 単語であった。この単語において、辞書に含まれる単語に関しては、そのセンチメントを入力ベクトルの極性値用の成分に代入した。一方で、辞書に含まれていない単語の該当成分には 0 を代入した。693,562 単語の内、辞書に含まれていなかったものは 262,508 単語存在した。すなわち 40%程の単語の極性値が 0 と

なっている。加えて、極性値は単語の分散表現ベクトルに追加しただけであり、201 次元の中の 1 次元のみしかしめない。これらの理由で、LSTM への全体の入力データに占める極性値の要素が非常に小さく、学習の際に極性値に適切な重みがつけられなかったと考えられる。

### 5.4 マルチタスク学習を用いた推定

表 6: マルチタスク学習を利用した超過リターンの推定の評価指標

	Pre	Recall	F1
マルチタスク学習	0.569	0.543	0.556

このようにマルチタスク学習では、リターンの方向性、ボラティリティの大きさともに改善させることができなかった。これは、この 2 つの情報に相関がないためではないかと考えられる。マルチタスク学習では、複数の学習対象のパラメータを共有することで性能の向上が期待される。学習対象が同じような特徴量を重要視するのであれば、複数の学習によってその特徴量がより抽出されるであろうが、そうでない場合はそれぞれの学習を邪魔してしまうであろう。今回の目標である超過リターンの方向とボラティリティは一見すると似た学習対象ではあるが、上述の通り、それぞれ非意見文と意見文といった相異なるセンテンスと深く結びついている。このことから、これら 2 つを決定づける特徴量は明確に異なるものであるとの推察ができる。そのため、マルチタスク学習はうまく機能しなかったのではないかと考えられる。

## 6 まとめ

本研究では、株式投資を見据え、投資家が重要視する個別銘柄の TOPIX に対する中長期の超過リターンの方向、及びボラティリティの大きさをアナリストレポートの本文を用いて推定することを目指した。アナリストレポートを構成する各センテンスをアナリストの意見文、非意見文に分類した後にこれらの推定を行った結果、超過リターンの方向は非予測文を、ボラティリティの大きさは意見文を用いることで高い性能で推定できることが判明した。なお、分類に用いる手法は、時系列データの学習に強みを持つニューラルネットワークである、Bidirectional LSTM に優位性が見られた。株価動向の予測の向上を目指し、近年金融情報学の分野で注目を浴びているセンチメントの利用と、汎化性能の向上が期待されるマルチタスク学習の利用を検討

した。センチメントの利用に関しては、文章全体センチメントを利用する方法と単語のセンチメントを利用する方法を検討したが、欠損値が生じない前者では性能が向上し、本研究でもセンチメントの有用性が確認できた。一方でマルチタスク学習については、学習対象に強い相関がないためか、性能を向上させることはできなかった。

## 参考文献

- [Bollen 11] Bollen, J., Mao, H., and Zeng, X.: Twitter mood predicts the stock market, *Journal of computational science*, Vol. 2, No. 1, pp. 1-8 (2011)
- [Caruana 97] Caruana, R.: Multitask learning, *Machine learning*, Vol. 28, No. 1, pp. 41-75 (1997)
- [伊藤 17] 伊藤友貴, 坪内孝太, 山下達雄, 和泉潔 F テキスト情報から生成された極性辞書を用いた市場動向分析, 人工知能学会全国大会論文集 2017 年度人工知能学会全国大会 (第 31 回) 論文集, pp. 2D21-2D21 一般社団法人 人工知能学会 (2017)
- [日本 18] 日本取引所グループ F 日本取引所グループ調査レポート, <https://www.jpx.co.jp/markets/statistics-equities/examination/01.html> (2018)
- [迫村 13] 迫村光秋, 和泉潔 F Twitter テキストマイニングによる経済動向分析, 第 9 回人工知能学会 ファイナンスにおける人工知能応用研究会 発表論文 (2013)

# 新聞記事からのテキストマイニングによる因果関係を考慮した アナリストレポートの自動要約文生成

## Automatic Summarization of Analyst Reports Based on Causal Relationship Text-Mined from News Reports

高嶺 航<sup>1\*</sup> 和泉 潔<sup>1</sup> 坂地 泰紀<sup>1</sup>  
松島 裕康<sup>1</sup> 島田尚<sup>1</sup> 清水 康弘<sup>2</sup>

Wataru Takamine<sup>1</sup> Kiyoshi Izumi<sup>1</sup> Hiroki Sakaji<sup>1</sup>  
Hiroyasu Matsushima<sup>1</sup> Takashi Shimada<sup>1</sup> Yasuhiro Shimizu<sup>2</sup>

<sup>1</sup> 東京大学大学院工学系研究科

<sup>1</sup> School of Engineering, The University of Tokyo

<sup>2</sup> 野村證券株式会社

<sup>2</sup> Nomura Securities Co., Ltd.

**Abstract:** In this paper, we proposed a new approach taking causal relationship into consideration with text mining for analyst report and news in automatic summarization. This approach can be used for reducing work load to read analyst report for institutional investors and gathering important economic information for investment decision for investment analysts. First, we analyzed the validity of the method in extracting causal relationship which can be evaluated from the textual data of Nomura Securities Co., Ltd. As a result, the using method could extract basis information of analyst's opinion from analyst report in higher precision, and we could confirm the style of analyst in expression of opinion and basis.

## 1 はじめに

近年、投資家に対する投資判断の支援を行う技術の必要性が高まってきている。投資家が重視する投資判断材料の一つにアナリストレポートがある。アナリストレポートとは、証券市場調査・分析の専門家である証券アナリストが、企業の経営状態や収益力などを調査し、その結果をまとめたレポートのことである。アナリストレポートには、企業の業績や株価に対する証券アナリストの予想が示され、その根拠として、その企業の取り組む事業の近況・財務状況（企業のファンダメンタルズ）や事業に影響を与える経済・政治・社会状況（マクロ経済のファンダメンタルズ）などが言及される。

例えば、酒井らは株式市場における次のような現象に注目している [1]。2012 年度上期のパナソニックの連結業績の発表では、前年同期比で売上高は減少したが、営業利益は増加したという内容であった。しかし、社長は「今回大幅な業績の下ぶれの根本的な原因は、本

業の不振にある」と語った。この発言が嫌気され、パナソニックの 2012 年 11 月 1 日の株価はストップ安となった背景がある。株価を予想する上で、場合によっては決算発表中の業績のみではなく、その背景にある本業に関する社長の発言を重視すべき時もある。そのため、アナリストレポート中で業績・株価予想の根拠として言及される情報の特徴を捉え、新聞記事などの媒体からその根拠の背景にある情報に絞って自動的に要約する技術が重要である。決算発表の時期には多くのレポート発行が集中し、特に機関投資家は時間の制約上、膨大なレポートの全てを熟読するのは難しく、レポートの内容を十分に把握できない場合も想定される。本技術により、投資判断材料に必要な情報を要約することで、レポートを読む負担が減り、時間の制約がある中でもレポートの内容の要点を把握することができる。またアナリストレポートを作成してきた証券アナリストのレポート作成の支援にも活用できる。

本手法では要約の過程で、新聞記事から抽出する背景表現とアナリストレポートから抽出する根拠表現を紐づける、証券アナリストの株価・業績予想に関する因果関係データベースが構築されるので、そのデータ

\*連絡先：東京大学大学院工学系研究科技術経営戦略学専攻  
〒113-8656 東京都文京区本郷 7-3-1 工学部 8 号館 530 室  
E-mail: m2018wtakamine@socsim.org

ベースから企業の業績・株価の予想につながるような根拠や背景となる経済情報を簡単に検索できるようになる。この目的に応用可能な技術として、近年、自然言語処理やテキストマイニング技術の進展により、テキストデータから自動的に重要な情報を抽出する技術が発達してきている [2][3]。しかし、これらの要約技術は、そのままでは事象の背景にある因果関係を考慮できない。一方、文の因果関係の構造に注目し、原因表現を取り出す手法も提案され始めている [4]。しかし、二つの異なる媒体から一つの要約文を生成する手法はまだ確立されていない。

本研究では、因果関係を考慮しながら別の媒体から補填的に情報を抽出し、要約文を自動生成する手法を提案し、その評価を行う。

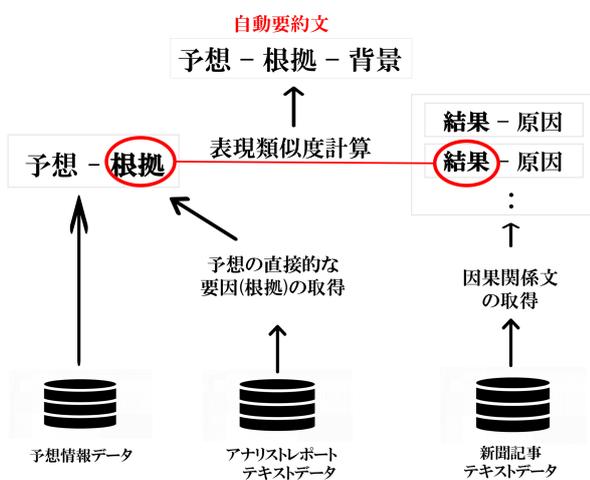


図 1: 提案手法の概説

含まれる因果関係における原因表現を証券アナリストによる企業業績・株価の予想の根拠情報として獲得する。ただし、この時、証券アナリストの予想情報とその予想の根拠情報は同文章内に出現するものと仮定している。つまり本手法では図2のように文章横断的に出現する因果関係表現は抽出しないこととする。また同様に、新聞記事からも因果関係の構造を抽出し、因果関係の結果表現のうち、獲得した証券アナリストの予想の根拠情報と表現が類似する文章を探索する。そして、類似性の高い因果関係における原因表現を根拠情報の背景情報として獲得する。このようにして獲得した、(1)証券アナリストの企業業績・株価予想、(2)予想の根拠(直接的な要因)、(3)根拠の背景をまとめ、アナリストレポートの要約文を自動生成する。

本自動要約手法の実装例として、Webサーバー上のシステムとして実装したものの動作画面を図3に示す。銘柄、期間を入力すると、すでに生成済みの要約文のうちから入力情報に合致する要約文を出力する。要約文の構成は、一文目に証券アナリストレポートの業績・株価予想、二文目に証券アナリストの予想の根拠、三文目にその根拠の背景を想定している。

文書 1: 業績予想を下方修正(結果表現)  
文書 2: ○○を織り込んだ。(原因表現)

図 2: 文章横断的に出現する根拠情報の例

## 2 提案手法

本章では、テキストデータから因果関係表現を抽出し、要約文を自動生成する手法について述べる。2.1節では本手法の概観、2.2節ではアナリストレポートおよび新聞記事からの因果関係表現抽出の概要、そして2.3節では、要約文における根拠の背景情報の獲得に用いた表現類似度計算手法の概要を述べる。

### 2.1 要約文生成手法の概説

本節では要約文生成手法の概要を述べる。全体の流れを図1に示す。まず、各アナリストレポートにおける証券アナリストの企業業績・株価の予想の情報を獲得する。次に、アナリストレポート本文中に出現する因果関係の構造を抽出し、結果表現に株価・業績予想が



図 3: 想定している提案手法を用いたシステムの動作画面

## 2.2 因果関係抽出手法

アナリストレポート・日経新聞記事から坂地ら [5] の手法を用いて因果関係表現を抽出する。この手法では、因果関係表現を特徴付ける手がかり表現と、手がかり表現に係る節の中で共通して頻繁に出現する共通頻出表現を定義する。最初に少数の手がかり表現と共通頻出表現を与えることで、互いに係り受け関係にある新たな共通頻出表現と手がかり表現が連鎖的に獲得される。この手法を用いる場合、アナリストレポートにおいては特にアナリストの予想を示す文の部分と、その予想の根拠を示す文の部分を分離して抽出する。前者を予想部、後者を根拠部と呼ぶ。

アナリストレポート中から抽出した予想部と根拠部の例を図 4 に示す。この文章の場合、「主力の制御事業の順調な拡大を」を根拠部、「主因に」が手がかり表現、「目標株価を上方修正」が予想部となる。酒井ら [6] は、アナリストレポートからアナリストの予想と根拠情報の抽出を行なっているが、アナリスト予想根拠文の抽出方法として、共通頻出表現の数を用いてアナリストの予想根拠文かどうかを判定している。本手法では、予想の直接的な要因を根拠情報と定義しており、結果表現に業績予想が含まれる因果関係の原因表現を証券アナリストによる企業業績・株価予想の根拠情報として抽出する。

### 主力の制御事業の順調な受注拡大を

(根拠部)

### 主因に、目標株価を上方修正

(手がかり表現)

(予想部)

図 4: アナリストレポートから抽出した予想部と根拠部の例

## 2.3 表現類似計算手法

本節では、アナリストレポートの根拠の背景情報を新聞記事から獲得するために用いた、二つの文章の表現類似度を計算する手法について述べる。本研究では、表現類似度  $s$  を以下の式のように話題性  $t$ 、文の表層  $w$ 、極性の一致度  $p$ 、文脈の類似性  $c$  の 4 つの構成要素として捉える。

$$s = t \cdot w \cdot p \cdot c \quad (1)$$

※以下の文章で、極性辞書と文脈の類似性について考慮に入れるべきか悩む。

- 話題性：トピックモデル (LDA[7]) による単語の分散表現を用いた文章の話題の類似度を算出
- 文の表層：Word2vec(Skip-gram[8][9]) による単語の分散表現を用いた文章の表層的な類似度を算出
- 極性の一致度：金融極性辞書 [10] を用いた単語の極性を計算し、文章間の極性がどれだけ一致するかを判定
- 文脈の類似性：アナリストレポートの根拠情報と新聞記事の結果表現の類似度を算出するだけでなく、新聞記事の原因表現との類似度も算出。より根拠情報の文意に沿った文章を抽出する。

LDA と Word2vec を用いて算出された二つのベクトル表現を用いることで、比較する二つの文書の話題性と表層的な類似度を算出する。ベクトル間類似度はコサイン類似度を用いた。  $A, B$  はそれぞれ文章  $\vec{A}, \vec{B}$  は、それぞれ文書  $A, B$  内にある名詞・動詞・形容詞の分散表現の相加平均を求めて算出した文書ベクトルである。

$$\text{cosine similarity} = \cos \theta = \frac{\vec{A} \cdot \vec{B}}{\|\vec{A}\| \|\vec{B}\|} \quad (2)$$

表 1: 実験に用いた手がかり表現の概要

手がかり表現の数	手がかり表現の例
109	織り込んで、見込んで、をきっかけに、背景に、考慮し、踏まえなど

## 3 実験

今回は、対象としているアナリストレポートにおいて、本文内にある証券アナリストが言及する予想の根拠情報を抽出する手法の妥当性を検証する実験を行なった。実験には、表 1 に示す手がかり表現を用いた。

実験データには、2011 年から 2016 年までの間に発行された 7927 件のアナリストレポートのうち文章内で因果関係表現が抽出できた 7716 件を用いた。予想アナリストレポートから抽出した因果関係の中から結果表現の部分に「目標株価」および「業績予想」に関する記述がある場合、その原因表現を予想の根拠として抽出している。なお、因果関係を抽出するにあたって、本実験では形態素解析器としては Mecab を使い、係り受け解析器としては Cabocha[11] を用いた。

表 2: 各予想に対する精度 (Precision)

抽出する予想	Precision
目標株価のみ	0.20
業績予想のみ	0.33
目標株価 $\cap$ 業績予想	0.04
目標株価 $\cup$ 業績予想	<b>0.44</b>

表 3: 表記揺れを考慮に入れた結果 (Precision)

手法	Precision
提案手法	0.44
提案手法 (表記揺れ考慮)	<b>0.83</b>

## 4 実験結果と考察

手法の評価手法に関しては、Precision(精度)を用いた。実験結果を表2に示す。検証した全項目で5割を下回る精度となり、因果関係ができた抽出した文のうち、結果表現にて目標株価と業績予想のいずれかに言及しているアナリストレポートの件数は、4割程度であった。必ずしも予想に対して直接的な表現を使用している訳ではないことが分かる。この要因として次の3点が挙げられる。

1. 証券アナリストの予想に表記揺れがある (例: 野村予想を上方修正, 利益予想を引き上げる)
2. 明確な根拠表現を回避する
3. 文章横断的な根拠表現が抽出できない

このうち、1の予想情報の表記揺れについて検討する。具体的には結果表現に含まれる記述として「目標株価」、「業績予想」に加え、「利益予想」、「野村予想」、「収益」、「売上高」等、計13個のフレーズがある場合、予想の根拠情報として抽出を行なった。目標株価および業績予想の根拠情報の抽出割合における表記揺れの考慮の結果を表2に示す。表記揺れを考慮することによって8割程度まで精度を向上することができた。予想情報の言及に関して、証券アナリストは複数の言い回しをしており、その表記揺れを考慮に入れて根拠情報を抽出する必要があることが分かった。本結果より、今回実験を行なったアナリストレポートの8割程度が予想の根拠情報を同一文章内にて言及しており、本手法における因果関係表現抽出手法の有用性が示すことができた。

## 5 まとめ

本研究では、新聞記事からの情報を活用し、文章内に出現する因果関係表現と文章間の表現類似性に着目したアナリストレポートの自動要約手法を提案した。その提案手法実現のために、アナリストレポートから根拠情報を抽出する手法の妥当性について実験を行った。表記揺れを考慮することによって、8割程度のアナリストレポートで同一文章内に証券アナリストの予想とその根拠情報が出現していることが分かり、本論文において用いた因果関係抽出手法の有用性が示された。また、実験結果を通じて証券アナリストのレポート内の書きぶりに関しても考察を行った。今後の課題として、要約文の評価データセットの作成、2節で紹介した表現類似度計算の精度向上に関する手法の考案、因果関係抽出の精度向上に寄与する手がかり表現の語義曖昧性解消手法の考案などが考えられる。

## 6 謝辞

本研究は、野村証券株式会社よりデータの提供をいただきました。この場を借りて、心より御礼申し上げます。

## 参考文献

- [1] 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.
- [2] Jahna Otterbacher, Güneş Erkan, and Dragomir R. Radev. Using random walks for question-focused sentence retrieval. In *Proceedings of the conference on Human Language Technology and Empirical Methods in Natural Language Processing*, pp. 915–922. Association for Computational Linguistics, 2005.
- [3] Katja Filippova, Mihai Surdeanu, Massimiliano Ciaramita, and Hugo Zaragoza. Company-oriented extractive summarization of financial news. In *Proceedings of the 12th Conference of the European Chapter of the Association for Computational Linguistics*, pp. 246–254. Association for Computational Linguistics, 2009.
- [4] Hiroyuki SAKAI and Shigeru MASUYAMA. Cause information extraction from financial articles concerning business performance. *IEICE Transactions on Information and Systems*, Vol. E91.D, No. 4, pp. 959–968, 2008.

- [5] 坂地泰紀, 酒井浩之, 増山繁. 決算短信 pdf からの原因・結果表現の抽出. 電子情報通信学会論文誌 D, Vol. 98, No. 5, pp. 811–822, 2015.
- [6] 酒井浩之, 柴田宏樹, 平松賢士, 坂地泰紀. アナリストレポートからのアナリスト予想根拠情報の抽出. 人工知能学会第 17 回金融情報学研究会, pp. 25–30, 2016.
- [7] David M Blei, Andrew Y Ng, and Michael I Jordan. Latent dirichlet allocation. *Journal of machine Learning research*, Vol. 3, No. Jan, pp. 993–1022, 2003.
- [8] Tomas Mikolov, Kai Chen, Greg Corrado, and Jeffrey Dean. Efficient estimation of word representations in vector space. *arXiv preprint arXiv:1301.3781*, 2013.
- [9] Tomas Mikolov, Ilya Sutskever, Kai Chen, Greg S Corrado, and Jeff Dean. Distributed representations of words and phrases and their compositionality. In *Advances in neural information processing systems*, pp. 3111–3119, 2013.
- [10] 伊藤友貴, 坪内孝太, 山下達雄, 和泉潔. テキスト情報から生成された極性辞書を用いた市場動向分析. 人工知能学会全国大会論文集 2017 年度人工知能学会全国大会 (第 31 回) 論文集, pp. 2D21–2D21. 一般社団法人 人工知能学会, 2017.
- [11] 工藤拓, 松本裕治ほか. 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.

# アナリストレポートと企業業績の関係解析 (第一報)

## Analysis of relationships between analyst reports and corporate performances (Preliminary Result)

北島良三<sup>1\*</sup> 酒井浩之<sup>1</sup> 上村龍太郎<sup>2</sup>  
坂地泰紀<sup>3</sup> 平松賢士<sup>4</sup> 栗田昌孝<sup>4</sup>

Ryozo Kitajima<sup>1</sup> Hiroyuki Sakai<sup>1</sup> Ryotaro Kamimura<sup>2</sup>  
Hiroki Sakaji<sup>3</sup> Kenji Hiramatsu<sup>4</sup> Masataka Kurita<sup>4</sup>

<sup>1</sup> 成蹊大学

<sup>1</sup> Seikei University

<sup>2</sup> 東海大学

<sup>2</sup> Tokai University

<sup>3</sup> 東京大学

<sup>3</sup> The University of Tokyo

<sup>4</sup> 株式会社アイフィスジャパン, 株式会社金融データソリューションズ

<sup>4</sup> IFIS JAPAN LTD., Financial Data Solutions, Inc.

**Abstract:** In this paper, we try to analyze relationships between analyst reports and corporate performances. The analyst reports are documents written about markets forecasts and they are useful for investment judgment. As analyst reports are written in natural language and data to be analyzed becomes complicated, a neural computational method called ‘potential learning’ which can interpret internal representations was used. As a result, we found that a generalization performance of the model was 0.6773 (accuracy) and words related to ‘word category: abstraction’ may affect corporate performances.

## 1 はじめに

本研究は、アナリストレポートと企業業績の関係について解析を行ったものである。アナリストレポートは、証券アナリストがレポート対象企業について、企業概要や事業概要、そして今後の業績予想などをまとめたレポートであり、投資判断に有用である。

このアナリストレポートであるが、記述内容・表現にアナリストの個性・心情が現れると考えられる。例えば確固たる根拠により業績上向きの判断とならない場合と、現状では上向くとは言えないものの、何らかの兆候を感じている場合には使用表現に差が生じていることが考えられる。本研究では、このアナリストレポートに記載されている内容と企業業績の間に、例えば特定表現の出現が業績変化に影響を与えるか?といった関係性の有無について解析を試みた。

関連研究として太田らは経営者予想とアナリスト予

想の精度とバイアスについて調べ、「アナリスト予想は、経営者予想の精度とバイアスに大きな影響を受けていた」[1]と報告している。また、近藤らはアナリストレポート中の株式推奨と利益予想について関連性を調査しており、例えば株式推奨変更がない場合において市場の反応の方向は「利益予想の修正方向によって決まる」[2]と報告している。近藤らの研究ではアナリストレポートから得た数値を解析に用いているが、本研究では数値データではなく文字データを解析対象としている点で異なっている。

## 2 解析手法

### 2.1 解析の流れ

本研究は、1. アナリストレポートから予想根拠情報(後述する)を抽出する。2. アナリストレポートと企業業績の関係を解析するための解析用データを作成する。3. アナリストレポートを入力として、業績の増減を出

\*連絡先: 成蹊大学理工学部情報科学科  
〒180-8633 東京都武蔵野市吉祥寺北町 3-3-1  
E-mail: r-kitajima@st.seikei.ac.jp

力する分類器を作成する。4. 解析結果を解釈する。という4つの流れにより実施される。以下各手順に沿って概要を述べる。

## 2.2 アナリストレポートからの予想根拠情報の抽出

はじめにアナリストレポートより「アナリスト予想根拠情報」を抽出する。これはアナリストレポートから情報抽出を行った小林らの研究により「アナリストレポートの内容を把握するうえで重要な、アナリスト予想の根拠情報を含む文」[3]と定義される文であり、アナリストレポートの核心をなす記述と言える。本研究ではこのアナリスト予想根拠情報を対象に、企業業績との関係を解析していく。アナリスト予想根拠情報は小林らの研究手法により抽出した。

抽出されたアナリスト予想根拠情報は銘柄(証券コード)毎にレポート発行年月順にまとめられ、本研究では2016年度決算期間(例えば2017年3月が決算月の企業の場合は2016年4月から2017年3月まで)に発行されたアナリストレポートを解析対象として用いた。またこれは後述する企業業績データと組み合わせた結果、440銘柄に対して記述されたアナリストレポートが解析対象となった。組み合わせた企業業績データであるが、これには売上高を使用した。より正確には2016年度売上高と2015年度売上高の差を求め、2016年度売上高の方が2015年度売上高よりも高い銘柄にはターゲットフラグとして「1」を、そうでない銘柄に「0」をそれぞれ割り当てた。

## 2.3 解析用データの作成

抽出されたアナリスト予想根拠情報は文字列データであるため、形態素解析を行わないと形態素情報を得ることができない。そこでアナリスト予想根拠情報に対して形態素解析を実施し、解析用データを作成した。形態素解析には日本語形態素解析システムであるJUMANを用い、「単語カテゴリ」と「単語ドメイン」を得た。両者はJUMANの辞書に登録されている各単語に関する分類情報であり、全部で22種類のカテゴリと12種類のドメインが登録されている。例えば単語「時計」は、カテゴリ「人工物-その他」、ドメイン「家庭・暮らし」となる。

ドメイン並びにカテゴリは各銘柄に対するアナリストレポートでの出現頻度(Term Frequency, TF)を、全アナリストレポートでの出現状態(文書頻度逆数, Inverse Document Frequency, IDF))により重み付けした値(TF-IDF)として記録し解析用データとした。ただし銘柄数440の半分よりも多い銘柄数でTF-IDF値

が0となっているものを除去し、表1に示す26のカテゴリとドメインを最終的に解析に用いた(変数番号15は本研究用に追加したカテゴリである)。

## 2.4 業績の増減を出力する分類器の作成

アナリスト予想根拠情報は言語データであるため解析データは複雑なものとなる。そこで、解析には複雑なデータの解析に定評のあるニューラルネットワークを使用した。しかし、ニューラルネットワークはブラックボックスと称されるほど内部表現の解釈が困難であり[4]、どの入力変数が学習に活用されたのかを理解することは容易ではない。そのため、本研究では重要変数の抽出が可能な「潜在学習」[5]と呼ばれるニューラルネットワークを解析に採用した。潜在学習はこれまでに北島らによって、太陽風を対象とした研究[6](数値予測問題での使用)、スーパーマーケットのPOSデータを対象とした研究[7](分類問題での使用)、等に用いられており、高い予測能力と解釈性が確認されている。

潜在学習は図1に示されているように自己組織化マップ(Self-Organizing Maps, SOM)と多層パーセプトロン(MultiLayer Perceptron, MLP)が基となっている二段階の学習から構成されている。図中の①は知識獲得段階と呼ばれる段階で、入力ニューロンの潜在性(後述する)を算出し、また、SOMに基づいて知識の獲得(学習)を行う段階である。潜在性とは「ニューロンの多様な状況に対応できる能力」と定義されるもので、「潜在性の高いニューロン(多様な状況に対応できるニューロン)は学習で重要な役割を果たすニューロンである」と解釈する。一般的なニューラルネットワークでは学習時に活用された入力を把握することは容易ではないが、潜在学習では潜在性を確認することで、活用された入力を把握することが可能である。

知識獲得段階での学習が終了すると、続いて予測段階(図中の②の処理)での学習が行われる。予測段階はMLPにて、そして、入力層-隠れ層間の重みの初期値に知識獲得段階で得られた、重みと潜在性より算出した値(重み×潜在性)がセットされ学習が行われる。通常MLPによる学習結果は初期重みに左右されるが、潜在学習ではこの初期重み設定により、獲得された知識に基づいた学習が期待できる。以上が潜在学習の概要である。なお、潜在学習にはいくつかのバリエーションがあり、ネットワーク構造や潜在性の算出方法などに違いがある。

本研究では、知識獲得段階において出力ユニットの数を27個<sup>1</sup>、予測段階において隠れユニットの伝達関数に双曲線正接関数を用い、ユニット数を27個、出力ユニットの伝達関数にソフトマックス関数を用い、ユ

<sup>1</sup>解析に使用したソフトウェアであるMATLABのSOM Toolboxの設定(mapsize:small)による。

表 1: 解析用データの変数一覧

変数番号	変数名	カテゴリ・ドメイン	変数番号	変数名	カテゴリ・ドメイン
1	人	カテゴリ	16	文化・芸術	ドメイン
2	組織・団体	カテゴリ	17	スポーツ	ドメイン
3	人工物-乗り物	カテゴリ	18	健康・医学	ドメイン
4	人工物-金銭	カテゴリ	19	家庭・暮らし	ドメイン
5	人工物-その他	カテゴリ	20	料理・食事	ドメイン
6	自然物	カテゴリ	21	交通	ドメイン
7	場所-施設	カテゴリ	22	教育・学習	ドメイン
8	場所-自然	カテゴリ	23	科学・技術	ドメイン
9	場所-機能	カテゴリ	24	ビジネス	ドメイン
10	場所-その他	カテゴリ	25	メディア	ドメイン
11	抽象物	カテゴリ	26	政治	ドメイン
12	形・模様	カテゴリ			
13	数量	カテゴリ			
14	時間	カテゴリ			
15	地名:国	カテゴリ			

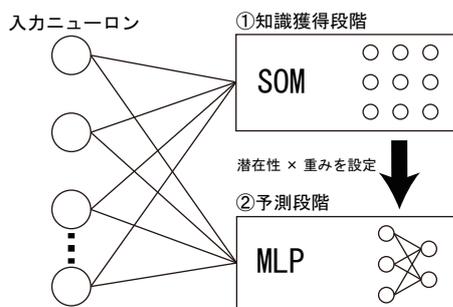


図 1: 潜在学習概要

ユニット数を 2 個, とした. なお層数は, 入力層 1, 隠れ層 1, 出力層 1 の 3 層構造である.

### 3 結果と考察

解析にあたり前述のデータを, 学習用 (データ総数の 70%), 過学習抑制用 (データ総数の 15%), 汎化能力試験用 (データ総数の 15%), の 3 つに分割した. さらにこれを, 分割比率は変わりなく, 各用途に使用されるデータサンプルがランダムに異なるものを 10 パターン作成して解析に用いた. すなわち 10 個のモデルを作成し解析を実施したわけであるが, 以下述べる分類器の性能はこの 10 個のモデルより得られた値の平均値を示している.

解析の結果, アナリストレポートは正解率: 0.6773, F 値: 0.6244 で売上増加企業と売上減少企業に分類できることを得た. これは潜在学習による分類と比較のために実施した, 多層パーセプトロン, 潜在性を使用しない潜在学習 (潜在学習とネットワーク構成は同じ

であるものの, 学習時に潜在性を使用しないもの), と比べ良好な結果 (結果を表 2 に示す) であったため, 潜在学習がアナリストレポート解析に有用であることを確認した (潜在学習による解析の特徴として標準偏差が小さいという点も確認できた).

続いてこの分類がどの入力変数を活用して得られたものなのかについて潜在性を用いて解釈を実施する. 図 2 は入力ユニットの潜在性を示したものである. この図より 11 番目のユニットの潜在性が高いことが確認できる. また潜在性と併せて入力層-隠れ層間の重みも確認したところ (図 3 (c) に潜在学習の重みを示す. この図は図形の大きさで重みの大きさを, 色で重みの符号 (緑: 正, 赤: 負) を示している), 11 番目, 13 番目, 14 番目, 24 番目の入力ユニットに重みが集中しており, これらの入力ユニットが学習に活用されていることが確認できた. この結果は潜在性が示している入力ユニットと一致しているため, 潜在性により重要入力ユニット (変数) の抽出ができていないと判断した. 参考までに図 3 (a) および (b) に多層パーセプトロン, 潜在性を使用しない潜在学習の重みを示しているが, これらは不特定多数の入力ユニットで正負大小様々な重みを持っており, 重要変数の解釈が困難 (a), 一部の入力ユニットであまり重みを持っていない等, 何らかの傾向は見られるものの, 傾向を絞ること (潜在学習では潜在性を確認することで入力ユニットの活用状態を把握できる) が困難 (b), という結果であった.

なお, 最も大きな潜在性を持った入力ユニットであるが, これは単語カテゴリ「抽象物」を意味するものであった. この結果より, この分類には抽象物に関する単語が重要な役割を果たしている傾向にあることが明らかになった. しかし, 大きな潜在性を持つ入力ユ

表 2: 解析結果

手法	正解率		F 値	
	平均値	標準偏差	平均値	標準偏差
多層パーセプトロン	0.6727	0.0809	<b>0.6266</b>	0.0793
潜在性を用いない潜在学習	0.6545	0.0673	0.5102	0.1849
潜在学習	<b>0.6773</b>	<b>0.0576</b>	0.6244	<b>0.0590</b>

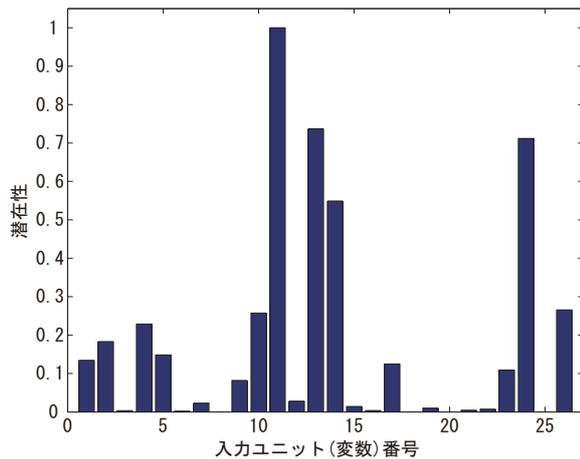


図 2: 潜在性

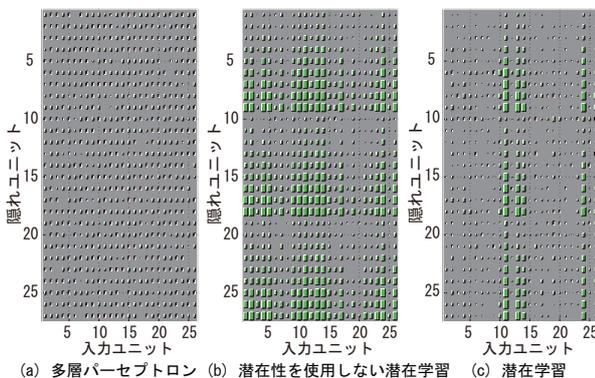


図 3: 入力層-隠れ層間の重み

ニットは 11 番目以外にも存在しているため、全体的な解釈にはこれら変数を加味する必要があり、また、具体的な単語の抽出も必要となる。これらは今後の課題である。

## 4 むすび

本研究は、アナリストレポートと企業業績の関係について解析を行ったものである。解析には、2016 年度決算期間に発行されたレポートから抽出されたアナリスト予想根拠情報と売上高を使用した。アナリストレ

ポートは自然言語で記述されているため、解析データが複雑になることが予想され、解析手法として複雑なデータの解析に定評のあるニューラルネットワークのうち、内部表現を解釈可能な「潜在学習」を用いた。

解析の結果、アナリストレポートは正解率：0.6773、F 値：0.6244 で売上増加企業と売上減少企業に分類でき、この分類には「単語カテゴリ：抽象物」に関する単語が重要な役割を果たしている傾向にあることが明らかになった。

## 参考文献

- [1] 太田浩司, 近藤江美: 経営者予想とアナリスト予想の精度とバイアス, MTEC ジャーナル, Vol. 23, pp. 33-58 (2011).
- [2] 近藤江美, 太田浩司: アナリストによる株式推奨と利益予想の情報内容, 証券アナリストジャーナル, Vol. 47, No. 11, pp. 110-122 (2009).
- [3] 小林和正, 酒井浩之, 坂地泰紀, 平松賢士: アナリストレポートからのアナリスト予想根拠情報の抽出と極性付与, 第 19 回金融情報学研究会予稿集, pp. 65-70 (2017).
- [4] 岩崎学: データマイニングと知識発見 -統計学の視点から-, 行動計量学, Vol. 26, No. 1, pp. 46-58 (1999).
- [5] Kamimura Ryotaro: Collective mutual information maximization to unify passive and positive approaches for improving interpretation and generalization, Neural Networks, Vol. 90, pp. 56-71 (2017).
- [6] 北島良三, 野和田基晴, 上村龍太郎: ニューラルネットワークによる太陽風物理量を用いた地磁気擾乱指数の予測, 成蹊大学 理工学部研究報告, Vol. 54, No. 2, pp. 9-15 (2017).
- [7] 北島良三, 遠藤啓太, 上村龍太郎: 入力ニューロンの潜在性に着目した小売店店舗の非継続来店顧客検知モデルの作成, オペレーションズ・リサーチ, Vol. 61, No. 2, pp. 88-96 (2016).

# 対話型 AI を活用した投資知識などの推定

## Estimation of Financial knowledge by Conversational AI

河合継<sup>1\*</sup> 新田翔<sup>1</sup> 木村祐輔<sup>1</sup> 眞嶋啓介<sup>1,2</sup> 西山昇<sup>3</sup>  
Kei Kawai<sup>1</sup> Sho Nitta<sup>1</sup> Yusuke Kimura<sup>1</sup> Keisuke Majima<sup>1,2</sup> Noboru Nishiyama<sup>3</sup>

<sup>1</sup> クリスタルメソッド株式会社

<sup>1</sup> Crystal method Co. Ltd.

<sup>2</sup> 慶応義塾大学環境情報学部

<sup>2</sup> Keio University Environment and Information Studies

<sup>3</sup> 千葉商科大学会計大学院 客員教授

<sup>3</sup> MBA Program, Graduate School of Accounting & Finance,  
Chiba University of Commerce

**Abstract:** 本研究では、投資信託の販売促進を行う対話 AI の研究を行った。全体の流れは、Seq2Seq を利用した雑談エンジンを通し会話の結果を返す。会話中の言葉の傾向の分析、会話によるリスク許容度の推定、そしてリスク許容度に応じた投資信託をすすめるという流れとなっている。今回の研究では、投資信託を薦める部分について取り組み、有価証券報告書や運用報告書月次レポートを用いて学習をした。学習器については LSTM の階層的 attention モデルの評価が各種方面で評価が高いのを鑑み、今回の研究でも利用した。また同時に学習が軽量でテキスト分類にもよく用いられる FastText も検証した。

## 1 はじめに

AI を活用することにより、働き型改革などを政府が唱えるなど、人間が働くことなく今までより便利な社会を作ることが重要視されている。また、人になる働き手を AI とすることで、少子高齢化社会でも皆が幸せに暮らせる社会を作る事が目標とされている。金融分野も例外ではなく、今まで銀行の窓口に人が立って、販売を促したり、預金勘定など対応していたが、そこに変わる AI など提案されつつある。また、昨今の AI 化進展とともに今まで人間でしかできないと考えられていた、高度な作業も AI で行う事が出来るようになってきた。まるで人間が話しているかのように電話で美容院の予約を取るような AI も登場してきている。AI に投資信託を売ることができるかという事を命題として、証券アナリストの方々も検討を重ねているようなインターネット記事なども見られるようになってきた。

また、近年著しく発展している AI 技術を金融市場の様々な場面に应用することが期待されている。自然言語処理 (Natural Language Processing, NLP) の分野では、記憶能力を備え、時系列データを処理可能な、ニューラルネットワークの一つである LSTM (Long Short Term Memory) をはじめとする RNN (Recurrent

Neural Network) を用いることで文書分類タスクで良好な結果を挙げている。また、FaceBook 社が作っている FastText もその学習時間の短さや軽快さでユーザーを増やしている。大量文書でも学習が行えることが特徴の一つで、Wikipedia 全文のような 100 万ページ以上の文書でさえも学習を行った実績がある。LSTM に関しては、階層的 attention モデルを導入することで、文書分類タスクにおいて、SVM (Support Vector Machine) や LSTM を上回るパフォーマンスが達成されている [3]。

これまで、このような AI 技術を用いて、決算短信や有価証券報告書の要約タスク等が行われてきた。これにより、専門知識を有する複数のアナリストが長時間を費やして要約をしていた運用報告書や月次レポートをはじめとする膨大なテキストデータの分析コストが大幅に削減されることが見込まれている。しかしながら株式や投資信託の販売促進を目的とした解析はほとんど行われていない。そこで本研究では、最終的な目的として、販売促進のニーズが高まっている投資信託のデータから、投資信託の販売促進を行う対話 AI の作成を掲げる。今回はそのプロセスの 1 つとして、投資信託の分類を試みる。

本論文では上述の階層的 attention モデルを用いることで、テキストデータから投資信託のパフォーマンス

\*連絡先：クリスタルメソッド株式会社  
E-mail: kawai@crystal-method.com

推測の検証を行う。

## 2 分析手法

### 2.1 FastText を使った文書分類

FastText は単語ベクトルを生成することができる。その単語を数値表現にしたものを分散表現と呼ぶ。分散表現は単語同士の近さを測ったり、演算（足し算・引き算など）を行う事ができる事が特徴となっている。CBOW と呼ばれる文章の中にある単語を前後の単語から推測するモデルや、skip-gram と呼ばれる、ある単語から、その前後に出てくる単語を推測するモデルが内部実装されている。

CBOW 解説

skip-gram 解説

Bag of Tricks for Efficient Text Classification 引用

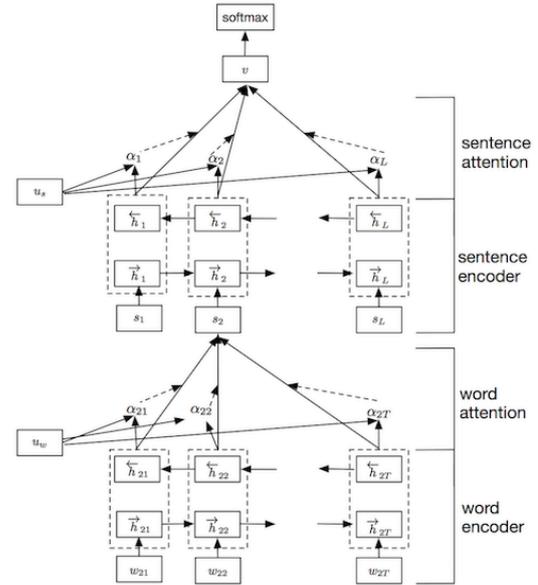


Figure 2: Hierarchical Attention Network.

### 2.2 階層的 attention モデル

階層的 attention モデルとは、単語レベルでの attention と文レベルでの attention の、二段階の attention を組み合わせたものである。文書分類を行う際、一般的に全ての単語および全ての文が重要であるとは限らない。金融業界の文書だと判定する場合には、金融に関する専門用語がより重要である。また文は単語から成り、文書は文から成り、文書は階層的構造を持っている。二段階の attention を用いてこれらの特徴を捉えることで、文書分類を高い精度で行うことができる。階層的 attention モデルは単語系列に対する Encoder と Attention、そして文系列に対する Encoder と Attention により構成されている。今回それぞれの Encoder は bidirectional GRU (Gated Recurrent Unit) により構成する。階層的 attention モデルの構造は図 1 に示す。階層的 attention モデルでは、単語および文ごとに attention を適用し、重要な単語や文が強調されることで、文書の階層的構造を捉えることができる。

ある文書に  $L$  個の文  $s_i$  ( $i = 1, \dots, L$ )、そしてそれぞれの文に  $T_i$  個の単語  $w_{it}$  ( $t = 1, \dots, T$ ) が含まれているとする。この時、単語系列に対する Encoder は、以下のように表される。ただし  $W_e$  は単語  $w_{it}$  の分散表現を獲得するための埋め込み行列であり、上付き矢印は双方向 GRU の方向を示している。

$$x_{it} = W_e w_{it}, t \in [1, T], \quad (1)$$

$$\vec{h}_{it} = \overrightarrow{\text{GRU}}(x_{it}), t \in [1, T], \quad (2)$$

$$\overleftarrow{h}_{it} = \overleftarrow{\text{GRU}}(x_{it}), t \in [T, 1]. \quad (3)$$

双方向 GRU の結果を結合し、 $h_t = [\vec{h}_{it}, \overleftarrow{h}_{it}]$  を次の単語系列に対する attention に渡す。attention では、以

図 1: 階層的 attention モデル

下に示すように 1 層の全結合層および softmax 関数を用いて、それぞれの単語  $w_{it}$  の重要度  $\alpha_{it}$  を計算する。

$$u_{it} = \tanh(W_w h_{it} + b_w) \quad (4)$$

$$\alpha_{it} = \frac{\exp(u_{it}^T u_w)}{\sum_t \exp(u_{it}^T u_w)}, \quad (5)$$

$$s_i = \sum_t \alpha_{it} h_{it}. \quad (6)$$

次に、文系列に対する Encoder は以下のように表す。

$$\vec{h}_i = \overrightarrow{\text{GRU}}(s_i), t \in [1, L], \quad (7)$$

$$\overleftarrow{h}_i = \overleftarrow{\text{GRU}}(s_i), t \in [L, 1]. \quad (8)$$

単語系列のときと同様に、双方向 GRU の結果は結合し、 $h_t = [\vec{h}_i, \overleftarrow{h}_i]$  とし、 $h_i$  を文系列の attention に渡す。

$$u_i = \tanh(W_s h_i + b_s) \quad (9)$$

$$\alpha_i = \frac{\exp(u_i^T u_s)}{\sum_i \exp(u_i^T u_s)}, \quad (10)$$

$$v = \sum_i \alpha_i h_i. \quad (11)$$

上式の  $v$  は文書に含まれる全文の情報を縮約したベクトルである。文書の分類の際には、 $v$  を全結合層に渡し、ソフトマックス関数を利用する。

### 3 実証分析

#### 3.1 データセット

##### 3.1.1 有価証券報告書のデータセット

有価証券報告書は金融庁が構築している、金融商品取引法に基づく有価証券報告書等の開示書類に関する電子開示システム EDINET と呼ばれるサイトで公開されている。EDINET には年 2 回、5 年分の有価証券報告書が掲載されている。今回の研究では、600 ファンド分、5 年分のデータをスクレイピングにより、EDINET から取得して PDF データ化を行った。各ファンド年に 2 本ずつの PDF2Text ライブラリによりテキストデータを生成し、Quick 社の Qr1 端末から価格データを取得した。有価証券報告書は全文利用して学習データとした。

有価証券報告書データの概要

##### 3.1.2 月次レポートのデータセット

実際の月次レポートおよび価格の時系列データを用いてデータセットの作成を行った。月次レポートに関しては、文章中から運用成績や今後の展望に関わる箇所を抽出し使用した。また正解データに関しては、価格の月次収益率を計算し、その収益率に基づき正解データを作成した。データの概要は表 1 の通りである。正解データは、収益率の中央値を閾値として、閾値に対しての大小に基づいている。

表 1: 月次レポートの概要

データの個数	730
期間	2016 年 1 月 ~ 2019 年 2 月
データ頻度	月次

#### 3.2 分析手法

##### 3.2.1 有価証券報告書の分析手法

有価証券報告書の分析方法としては、当該始値より次の始値が上がっている場合利益 (lavel1)、当該始値より次の始値が下がっている場合損益 (lavel2) のように文章に分類フラグを付けて FastText の学習関数で学習させた。

ラベルがついている表

2014 年 ~ 2018 年上半年期までのデータを学習データとして、2018 年下半期の学習データを評価用データとしてりようして、検証を行った。

##### 3.2.2 月次レポートの分析手法

投資信託の分類として、価格のデータに基づいた、文書の 2 クラス分類を行う。文書データの分散表現獲得には、日本語の Wikipedia のデータから学習させた FastText を使用した。分散表現の次元数は 300 とした。階層的 attention モデルの学習に使用したパラメータは表 2 の通りである。学習エポック数に関しては、学習の進み具合を考慮してある。

表 2: 学習パラメータ

最適化関数	Adam
損失関数	交差エントロピー
学習率の初期値	0.001
学習エポック数	54
バッチサイズ	32
GRU のユニット数	150

#### 3.3 分析結果

##### 3.3.1 FastText

##### 3.3.2 階層的 attention モデル

階層的 attention モデルによる投資信託のリターンの推定についてまとめる。図 2 より、Loss に関しては学習データに対しては 0.35 付近まで下がっているが、検証データに関しては 0.60 程度で下がらなくなっている。Accuracy のに関しては、学習データに対しては 80% を超え、検証データに対しても 70% を超えている。

### 4 まとめと今後の課題

本研究では投資信託の販売促進を目的とした対話 AI の作成を最終目標とし、その取り掛かりとして投資信託のテキストデータから、パフォーマンスの推測を行った。階層的 attention モデルは自然言語処理の分野で高い精度を誇り、投資信託の月次レポートに含まれる運用成績や今後の展望に関する文章から、投資信託のパフォーマンス推測が行えることが期待された。

実際に、階層的 attention モデルによる予測は検証データに対しても 70% を超え、階層的 attention モデルを用いることで、文書分類を高い精度で行えることがわかった。しかしながらデータセットの少なさ等、改善点は残っている。

今後の予定として、投資信託の文書分類の精度向上を目指す。その後は顧客の属性と文書分類を紐づけて、投資信託の販売促進を行う対話 AI の作成に取り組む。

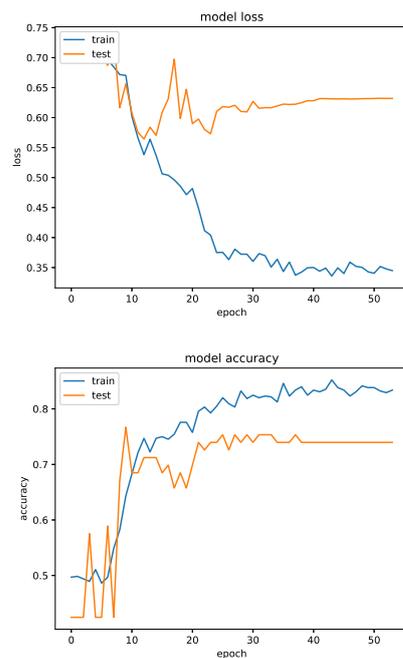


図 2: 階層的 attention モデルの Loss (上) と Accuracy (下) の推移

## 謝辞

本研究を進めるにあたり、データ提供をしていただいた株式会社 QUICK 様には大変お世話になりました。深く感謝致します。

## 参考文献

- [1] Xiang Zhang, Junbo Zhao, and Yann LeCun: Character-level convolutional networks for text classification, arXiv:1509.01626 (2015)
- [2] Duyu Tang, Bing Qin, and Ting Liu: Document modeling with gated recurrent neural network for sentiment classification, In Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing, pp. 1422-1432 (2015)
- [3] Yang, Zichao., et al: hierarchical attention networks for document classification, Proceedings of the 2016 Conference on the North American Chapter of the Association for Computational Linguistics, Human Language Technologies. (2016)

# 関連記事を用いた市況分析コメントの自動生成

## Automatic generation of market analysis comments by using relevant articles

酒井 浩之<sup>1\*</sup> 坂地 泰紀<sup>2</sup> 和泉 潔<sup>2</sup> 松井 藤五郎<sup>3</sup> 入江 圭太郎<sup>4†</sup>  
Hiroyuki Sakai<sup>1</sup> Hiroki Sakaji<sup>2</sup> Kiyoshi Izumi<sup>2</sup> Tohgoroh Matsui<sup>3</sup> Keitaro Irie<sup>4</sup>

<sup>1</sup> 成蹊大学<sup>1</sup> Seikei University <sup>2</sup> 東京大学<sup>2</sup> The University of Tokyo

<sup>3</sup> 中部大学<sup>3</sup> Chubu University

<sup>4</sup> 三菱UFJ国際投信<sup>4</sup> Mitsubishi UFJ Kokusai Asset Management

**Abstract:** 本研究では、経済新聞記事などの経済テキストから、日経平均株価などの市況について言及している記事を抽出し、それらの内容を自動的に要約することによりマーケットレポートにおける市況分析コメントを自動生成する手法の開発を行う。しかし、日経平均株価の市況について言及している記事のみでは、指定した期間において重要な内容について言及している文の数が少なく、そのために重要な内容が市況分析コメントに含まれないことがある。そこで本研究では、ある期間において日経平均株価に影響を与えたイベントを推定し、そのイベントについて述べた記事を関連記事として自動的に検索し、検索された関連記事をも使用することで、生成する市況分析コメントの精度を高める手法を提案する。

## 1 はじめに

近年、証券市場における個人投資家の比重が増大しており、個人投資家に対して投資判断の支援をおこなう技術の必要性が高まっている。そのため、人工知能分野の手法や技術を、金融市場における様々な場面に応用することが期待されており、例えば、膨大な金融情報を分析して投資判断の支援を行う技術が注目されている。その一例として、日本銀行が毎月発行している「金融経済月報」や経済新聞記事をテキストマイニングの技術を用いて解析し、経済市場を分析する研究などが盛んに行われている [1][5]。

本研究では、毎月のファンドの月次運用報告書に記載される市況分析コメントを自動生成する手法を提案する。市況分析コメントとは、例えば「8月の国内株式市況は、中国の景気減速懸念が台頭したことなどを背景とした世界的な株安を受けて大きく下落しました。」のような、その月における株価が大きく変動したイベント（例えば、「人民元の基準値切り下げ」）について述べ、株価が変動した理由を分析した文書である。以下に、2015年1月のファンド月次運用報告書に記載された市況分析コメントの一部を示す。

1月の国内株式市況は、ギリシャのユーロ離脱懸念やスイスフランの対ユーロ無制限介入終了による外国為替市場の混乱などを受けて大きく下落しましたが、ECB（欧州中央銀行）が量的緩和を導入すると観測が強まると国内外の株式市況が反発、買い戻される展開となりました。...

上記のような市況分析コメントを記述するために、ファンド運用の担当者は①日経平均株価が大きく動いた記事を調べ、②その前後にあったイベントを確認し、③その記事の中から株価が変動した理由について述べている文を選択し、④まとめる、という作業を毎月、行う必要がある。これらの作業は、複数のファンドを担当する運用担当者にとって大きな負担となっているが、市況分析コメントについては運用担当者が独自の視点を生かして記述するというよりは、客観的に正確な記述をすることを求められるため、市況分析コメント作成については自動化を行い、自動化されたコメントの確認作業に専念した方が効率的な業務運営につながると思われる。

そこで、酒井らは、上記の①日経平均株価が大きく動いた記事の判定、②その前後にあったイベントの確認、③その記事の中から株価が変動した理由について述べている文を抽出、といった処理を自動化し、③の処理によって抽出された文を時系列順に並べることで市況分析コメントを自動生成する手法を提案した [8]。

\*連絡先：成蹊大学 理工学部 情報科学科  
〒180-8633 東京都武蔵野市吉祥寺北町 3-3-1  
E-mail: h-sakai@st.seikei.ac.jp

†本論文に示された所見は著者自らのものであり、所属する組織の公的な立場を代表するものではない。

酒井らの手法の概要は以下のようになっている。

- Step 1:** 一か月分の日経新聞記事から日経平均株価について述べた記事（以降、分析記事と定義）を深層学習により抽出。
- Step 2:** 分析記事の集合から、その期間における重要なキーワード（以降、重要キーワード）を抽出（例：人民元、中国人民銀行）
- Step 3:** Step 1 で抽出した分析記事集合より、日経平均が変動した要因について述べた文（以降、要因文と定義）を抽出。
- Step 4:** Step 3 で抽出した要因文集合と、Step 2 で抽出した重要キーワード集合を使用し、重要な要因文を判定
- Step 5:** Step 4 で判定された重要な要因文を時系列順にならべ、市況分析コメントとする

しかし、酒井らの手法によって生成された市況分析コメントには、その月で起こった重要なイベントが含まれないことがあった。例えば、2015年1月において、「ギリシャ総選挙において反緊縮財政派が優勢」や「スイス国立銀行がスイスフランの対ユーロでの無制限介入終了を急遽発表」といった重要なイベントが自動生成したレポートに含まれておらず、Step 2においても重要なキーワードである「スイスフラン」「ギリシャ総選挙」なども取得されていなかった。

原因を調査したところ、入力とした2015年1月の分析記事において、スイスフラン高について述べている記事は1月16日の1つしかなく、重要なキーワードとして抽出されていなかった。同じく、「ギリシャ総選挙において反緊縮財政派が優勢」について述べている記事も1月26日の1つしかない。

本タスクは、複数の記事から1つの要約を生成する複数文書要約（例えば、文献 [6]）とみなすことができる。複数文書要約では、入力として複数の記事が与えられ、それらの記事から重要な文を抽出し、重要な文同士の冗長性を排除してまとめるという処理を行い、入力された記事の内容をまんべんなく含むような要約を生成することが求められる。複数文書要約では、通常、入力した複数の文書において多く、かつ、複数の文書にまんべんなく出現する語を重要キーワードと認定し、その重要キーワードから重要文を抽出するが、本タスクではこの仮定が成り立っていなかった。しかしながら、1月の（分析記事以外を含む）記事全体には、「ギリシャ総選挙において反緊縮財政派が優勢」に関する記事や「スイス国立銀行がスイスフランの対ユーロでの無制限介入終了」に関する記事は、それなりに多く出現していることが期待できる。そのため、本研究では、ある期間の分析記事のみから市況分析コメントを

生成するのではなく、分析記事に記載されているイベントを推定し、そのイベントに関連する記事を検索し、検索された関連記事をも使用して、市況分析コメントを生成する。

関連研究として、決算短信を対象として様々な情報を抽出する研究がある。酒井らは決算短信から業績要因を含む文（例えば「半導体製造装置の受注が好調でした。」）を抽出する手法を提案している [7][9]。坂地らは決算短信から原因・結果表現を抽出する手法を提案している [10]。北森らは決算短信から業績予測文（今後の業績予測に関する情報が記述されている文）を抽出する手法を提案している [2][3]。いずれの研究も抽出対象である情報を抽出するために有効な手がかり表現に着目し、それらの表現をブートストラップ的に自動的に獲得、もしくは、人手にて用意している。本研究においても、③その記事の中から株価が変動した理由について述べている文を抽出する処理のために手がかり表現を用いるが、その手がかり表現の獲得のために、酒井らの決算短信から業績要因を抽出する手法 [7] において提案された手がかり表現の自動獲得手法を用いている。

## 2 関連記事を用いた市況分析コメント自動生成手法

### 2.1 深層学習による分析記事の抽出

市況分析コメントを自動生成するための情報源として日経平均株価について言及している記事を使用する。そのため、一か月の日経新聞記事集合から日経平均株価について言及した記事（分析記事）を深層学習にて自動的に抽出する。分析記事の自動抽出手法については酒井らの手法 [8] と同一なので、手法の詳細は割愛するが、概要を述べると以下ようになる。

- Step 1** 2000年から2014年までの日本経済新聞記事のタイトルに「日経平均」が含まれている記事から、学習データを自動生成する
- Step 2** 自動生成された学習データから入力層の要素となる語（素性）を選択する。
- Step 3** Step 1 で生成した学習データと素性を用いて、深層学習にて一か月の日経新聞記事集合から分析記事を抽出する

### 2.2 関連記事の検索と重要キーワードの抽出

前節で抽出された分析記事に記述されているイベントについての記事（以降、関連記事と定義）を、その

月の記事集合から検索する。例えば、2015年1月の記事集合から、以下の記事が関連記事として検索される。

- 株・為替、波乱含みに、スイスフラン・ショックでユーロ安、欧州中銀、量的緩和が焦点
- 緩和マネー、日米欧株上昇、欧州量的緩和、市場に安心感、ギリシャ・原油なおリスク
- NY金、3週ぶり高値、ギリシャ政局混迷、買い先行

さらに、検索された関連記事集合から、その月における重要キーワードを抽出する。上記の手法により、2015年1月の関連記事から抽出した重要なキーワードの例を以下に示す。

原油安、ギリシャ総選挙、ECB、金属取引所相場、欧州中央銀行、原油先物相場、スイス国立銀行、スイスフラン

関連記事を用いることで、酒井らの手法では抽出できなかった「ギリシャ総選挙」や「スイスフラン」といった語が、重要キーワードとして抽出できるようになった。

## 2.3 分析記事からの要因文の抽出

分析記事から日経平均が大幅に変動した理由について言及している文（要因文）を抽出する。例えば、以下のような文を抽出する。

- ギリシャへの金融支援協議が難航していることや、中国・上海株の値動きへの警戒感から、投資家のリスクオフの動きが強まった。
- 米消費者物価指数の上昇やイエレン米連邦準備理事会議長が年内の利上げに前向きな姿勢を示し、為替相場が円安に向かった。

要因文の抽出は、「強まった」のような手がかり表現や、前節で抽出したその期間における重要なキーワードを使用して抽出する。手がかり表現の獲得手法は酒井らの手法 [7] と同一であるため割愛する<sup>1</sup>。

分析記事からの要因文の抽出は、分析記事から手がかり表現と重要キーワードがともに含まれている文を抽出することで行い、さらに、重要キーワードに付与されたスコアを用いることで要因文にスコアを付与し、要因文のスコアが大きい順に抽出する。

<sup>1</sup>ただし、最初に入力する初期手がかり表現は、本研究における抽出対象にあわせて変更している。

## 2.4 市況分析コメントの自動生成

前節で抽出された要因文を時系列順にならべ、市況分析コメントを生成する。しかし、抽出された要因文には同じ内容について記述されている文が含まれている可能性がある。そのため、抽出された要因文間の類似度を求め、類似度が大きい文の一方を除去することで、同一内容の文が市況分析コメントに含まれることを防止する。

例として、2015年1月の記事集合から生成した市況分析コメントを以下に示す。

今月の国内株式市況は日経平均株価が17408.71円から17674.39円まで上昇した。

前半は、17108.70円まで下落した。原油安やギリシャの政情不安などで5日の欧州や米国の株価が大幅に下落し、東京市場にも売りが波及した。業種別では原油安が響く鉱業の下げが目立った。資源国の経済への不安が高まったことで海外の金融・資本市場で動揺が広がり、東京市場にも及んでいる。ギリシャにユーロ離脱の懸念が浮上し、欧州経済の混乱への警戒感も株価を押し下げている。世界の市場を動揺させている原油価格の下落が止まらず、欧州経済懸念も強い。

後半は、17674.39円まで上昇した。原油価格の一段安やギリシャの政情不安が引き続き意識され、相場全体の先行き不透明感が増した。欧州中央銀行（ECB）の量的緩和観測を好感したものの、市場では止まらない金利低下への戸惑いも広がる。

第一文と「前半は...」「後半は...」から始まる文は、その月の日経平均株価の変動率から自動生成している。

2015年6月の記事集合から生成した市況分析コメントを以下に示す。後述の評価では、6月の市況分析コメントの評価値が最も高かった。

今月の国内株式市況は日経平均株価が 20569.87 円から 20235.73 円まで下落した。

前半は、20387.79 円まで下落した。米利上げ観測が再燃するのは直近の雇用統計の内容が良好で、景気回復期待が強まったからだ。

後半は、20235.73 円まで下落した。日本時間 18 日未明に米連邦公開市場委員会 (FOMC) の結果発表を控え、買いが手控えられた。FOMC ではメンバーの金利見通しが引き下げられ、市場で利上げが緩やかになるとの見方が強まった。前日の欧米株高やギリシャ債務問題の解決に向けた動きを好感した買いが入った。ギリシャの支援協議進展を好感したものだったが、再び交渉が難航すると相場は弱含んだ。今週は小売りを中心に 3~5 月期決算発表が本格化する。ギリシャの債務不履行が世界的な金融不安を招きかねないとの懸念が重荷になった。

2015 年 10 月の記事集合から生成した市況分析コメントを以下に示す。

今月の国内株式市況は日経平均株価が 17722.42 円から 19083.10 円まで急騰した。

前半は、18096.90 円まで上昇した。2 日発表の米雇用統計は低調な内容で、米国の早期利上げ観測がやや後退。中国など新興国経済の減速懸念から、9 月に入って企業業績への楽観論は急速に修正されてきた。前週末の米国株高に加え、環太平洋経済連携協定 (TPP) 交渉の進展が好感された。一部で追加緩和への思惑が浮上し、決定会合に向けて売り建てておいた先物を買戻す動きもみられた。9 月の中国製造業購買担当者景気指数 (PMI) の改善や米新車販売好調などでマクロ指標への不安が後退。10 月末には日銀が追加緩和するとの観測も強まる。

後半は、19083.10 円まで急騰した。中国人民銀行 (中央銀行) が 23 日に金融緩和策を発表し、中国景気への警戒感が後退。

### 3 評価

本手法の評価を行うため、本手法を実装した。実装にあたり、形態素解析器として MeCab<sup>2</sup>、係り受け解析器として CaboCha[4] を使用した。評価方法は、実際に運用担当者が作成した市況分析コメント (2015 年 1 月~12 月) と、その期間の日経新聞記事を使用して本手法により自動生成された市況分析コメントとを比較

<sup>2</sup><http://taku910.github.io/mecab/>

表 1: 評価結果

期間	本手法	比較手法	運用担当者
1 月↑	0.47	0.42	0.72
2 月↑	0.41	0.39	0.39
3 月↑	0.54	0.42	0.74
4 月↑	0.40	0.38	0.60
5 月↑	0.56	0.38	0.40
6 月↓	0.67	0.45	0.60
7 月↑	0.56	0.45	0.47
8 月↓	0.51	0.41	0.88
9 月↓	0.46	0.50	0.88
10 月↑	0.49	0.33	0.87
11 月↑	0.43	0.57	0.69
12 月↓	0.48	0.63	0.46
平均	0.50	0.45	0.63

して行った。具体的には、ある期間における運用担当者が作成した市況分析コメントと自動生成された市況分析コメントとの類似度を、Doc2vec を用いて求める。そして、その期間における運用担当者が作成した市況分析コメントとの類似度の平均を評価値とした。ここで、比較手法として以下の手法と比較した。

**比較手法:** 酒井らの手法 [8] によって生成された市況分析コメント

**運用担当者:** 運用担当者が作成した市況分析コメントの 1 つを選択

運用担当者は理想的な結果に基づく評価値となる。結果を表 1 に示す。なお、期間の矢印 (↑, ↓) は、その期間において日経平均が上昇したか下落したかを示す。

### 4 考察

本手法と比較手法を比較すると、9 月、11 月、12 月を除く全ての月で、本手法がよい評価結果を得た。また、全期間の評価値の平均も本手法が上回り、その月のイベント内容に左右されずに、平均して高い評価値をだしていることが分かる。これは、本手法は、分析記事における記述が少ないイベントでも関連記事を使用することで、適切に重要キーワードへの重み付けができるからであると考えられる。また、比較手法では抽出された要因文同士の類似性の判定を行っておらず、類似した内容の文が生成された市況コメントに含まれている場合があったが、本手法では、類似している文の一方を除去することで、その月に起こったイベントを幅広く網羅している。しかし、そのことが評価値を下

げることもあった。例えば、比較手法のほうが高い評価値である12月の記事から生成された市況分析コメントを比較する。まずは、比較手法によって生成された市況分析コメントを示す。

前日の欧州中央銀行理事会で決まった追加の金融緩和策が市場の期待に届かず、失望売りが広がった。円高・ドル安が進んだのも重荷となり、輸出株の下落が目立った。幅広い範囲の業種に売り注文が広がり、東証1部上場企業の約9割が値下がりした。前週末の米国株の大幅下落に加え、15～16日には米連邦公開市場委員会が控え、日本株の先行きにも不透明感が高まっている。15日の東京株式市場で日経平均株価は大幅に続落し、ほぼ2カ月ぶりの安値を付けた。利上げの是非を判断する米連邦公開市場委員会の開催を前に投資家のリスク回避姿勢が強まり、東証1部の8割超の銘柄が下げた。

次に、本手法によって生成された市況分析コメントを示す。

今月の国内株式市況は日経平均株価が20012.40円から19033.71円まで下落した。前半は、18565.90円まで大幅に下落した。前日の欧州中央銀行（ECB）理事会で決まった追加の金融緩和策が市場の期待に届かず、失望売りが広がった。後半は、19033.71円まで上昇した。原油価格の下げ止まりも投資家心理を改善させた。16日の米連邦公開市場委員会（FOMC）の結果発表を控えて手じまい売りが続き、ほぼ全面安の展開。米連邦準備理事会（FRB）が利上げを決め、当面の金融政策の不透明感が払拭されたことが好感された。原油安が一服し、投資家が過度にリスクを避ける姿勢が和らいだ。2016年は低インフレ懸念が強まるとの見方が背景にあり、新興国の景気減速や通貨安が拍車をかけている。米利上げは米国の需要を抑えるだけでなく長短金利差が縮小し、銀行収益の圧迫要因となる。

この月は、「欧州中央銀行の追加金融緩和策」についてと、「FOMC（米連邦公開市場委員会）での政策金利引き上げ」についてが主な内容であり、それについてのみを記述した比較手法のほうが高い評価値を示した。本手法は、類似した要因文の一方を除去するため、基本的に1つのイベントは1つの要因文のみとなる。そのため、「原油価格の下げ止まり」といった多くのイベントが含まれた分析コメントとなり、結果として、評価値が低くなることもあると考える。

## 5 まとめ

本稿では、経済新聞記事などの経済テキストから、日経平均株価の市況について言及している記事のみを抽出し、それらの内容を自動的に要約することによりマーケットレポートにおける市況分析コメントを自動生成する手法について述べた。本手法では、まず経済新聞記事から深層学習により日経平均株価について言及している記事（分析記事）を抽出し、さらに、その分析記事と関連している記事（関連記事）を検索する。そして、関連記事を用いて重要なキーワードを抽出した。次に分析記事の中からその理由について言及している文（要因文）を抽出し、類似した要因文を除去しつつ、重要なキーワードを含む要因文を時系列順に並べることで市況分析コメントを自動生成した。評価の結果、関連記事を用いていない既存手法[8]より概ね高い評価値を達成した。

## 参考文献

- [1] 和泉潔, 後藤卓, 松井藤五郎: 経済テキスト情報を用いた長期的な市場動向推定, 情報処理学会論文誌, Vol. 52, No. 12, pp. 3309-3315 (2011).
- [2] 北森詩織, 酒井浩之, 坂地泰紀: 決算短信 PDF からの業績予測文の抽出, 電子情報通信学会論文誌 D, Vol. J100-D, No. 2, pp. 150-161 (2017).
- [3] Kitamori, S., Sakai, H. and Sakaji, H.: Extraction of sentences concerning business performance forecast and economic forecast from summaries of financial statements by deep learning, *IEEE Symposium on Computational Intelligence for Financial Engineering & Economics*, pp. 67-73 (2017).
- [4] 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).
- [5] 藏本貴久, 和泉潔, 吉村忍, 石田智也, 中嶋啓浩, 松井藤五郎, 吉田稔, 中川裕志: 新聞記事のテキストマイニングによる長期市場動向の分析, 人工知能学会論文誌, Vol. 28, No. 3, pp. 291-296 (2013).
- [6] 酒井浩之, 増山繁: ユーザの要約要求を反映するためにユーザとのインタラクションを導入した複数文書要約システム, 日本知能情報ファジィ学会誌, Vol. 18, No. 2, pp. 265-279 (2006).
- [7] 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. J98-D, No. 5, pp. 172-182 (2015).

- [8] 酒井浩之, 坂地泰紀, 和泉潔, 松井藤五郎, 入江圭太郎: 経済テキストからの市況分析コメントの自動生成, 第 20 回 金融情報学研究会, pp. 44-49 (2018).
- [9] 酒井浩之, 松下和暉, 北島良三: 学習データの自動生成による決算短信からの業績要因文の抽出, 日本知能情報ファジィ学会誌 (2019(採録決定)).
- [10] 坂地泰紀, 酒井浩之, 増山繁: 決算短信 PDF からの原因・結果表現の抽出, 電子情報通信学会論文誌 D, Vol. J98-D, No. 5, pp. 811-822 (2015).

# 経済因果チェーン検索のシステム紹介と応用

## Economic Causal Chain Search System and its Application

和泉 潔<sup>1</sup> 坂地 泰紀<sup>1</sup>

Kiyoshi Izumi<sup>1</sup>, Hiroki Sakaji<sup>1</sup>

<sup>1</sup> 東京大学大学院工学系研究科 システム創成学専攻

<sup>1</sup>Department of Systems Innovation, School of Engineering, the University of Tokyo

**Abstract:** In this research, we introduce a system for searching causal relationships of events related to economics and finance in a chain-like manner from a database extracted from economic text data. This system also introduces service application ideas such as inferring economic ripple effects from events entered by users and presenting related stocks tracing the causal chain from news articles.

### はじめに

経済ニュース記事を読んでいると、株価の動きや商品の売り上げ、雇用や貿易など様々な経済事象に関する原因と結果の関係の記述がよく出てくる。例えば「将来の少子高齢化が〇〇を引き起こし、それに関連した〇〇に関する需要が増えることが予想される」とか「現在の株価下落は〇〇による市場参加者のリスク警戒心理の高まりを反映している」など、ある事象の経済的な波及効果やその事象の原因について述べている。

しかし経済現象のように人間の行動が関係する事象の因果関係を、数値データだけから統計的に解析することは難しい。なぜなら、人間が原因事象をどのように認識して、それに対してどのような行動を取るのかという行動ルールが因果関係の鍵となっているからである。時と場合によって因果関係が変化する。自然科学的現象のように数値データの統計分析で、客観的かつ普遍的な因果系列を取り出すことはほぼ不可能である。

そこで、本研究では人間が認識した因果関係が含まれていると思われる経済テキストデータを解析し、経済分野に関わる因果関係のデータベースを構築する。さらに、特定の事象を表すフレーズから派生する因果系列を検索する手法を開発する。本手法を用いて、ユーザが入力した語句に対して因果系列を表示し、ユーザが適切な系列に選択したり適切でない系列を削除したりできるシステムを実装した。本システムで作成された因果チェーン、経済的な波及効果と要因列挙が可能となる。

本稿では、因果チェーン検索システムと、本シ

テムやアルゴリズムを用いた応用例を紹介する。

### 経済的因果関係の抽出とデータベース構築

人間が認知した因果関係について記述されたテキストデータを解析し、そこから因果関係を抽出する技術が必要となる。本システムでは、決算短信という上場企業が業績や財務状況を開示するために定期的に発行しているテキストから、手がかり表現を用いた手法[1]により因果関係を抽出した。

- 使用したテキストデータ：2012年10月から2018年5月に約2,300社が発行した約2万個の決算短信テキスト

- 抽出した因果関係：1,078,542個

抽出された因果関係は、決算短信の発行された日付、決算短信を発行した銘柄などと一緒にデータベースに保存される。

### 因果チェーンの構築アルゴリズム

上述の経済因果データベースから、特定の語句から関連する因果系列を構築する手法には、[2,3]を基に改良した手法を用いた。具体的には以下の4ステップからなる(図1)。

1. ユーザがフレーズを入力する。最初は終端ノードを入力テキストとする。
2. 終端ノードの表現と一定の類似性がある因果関係を経済因果データベースから選択し、ネットワーク追加候補とする。
3. Step 2で抽出したネットワーク追加候補と終端ノードの組み合わせについて因果関係ノード

間の類似度を計算する.因果関係ノード間の類似度が閾値 $\alpha$ 以上あるときにノードをネットワークに追加してネットワークを拡張する.

- Step 3 でネットワークに追加したノードを終端ノードとして Step 2, Step 3 を繰り返す.

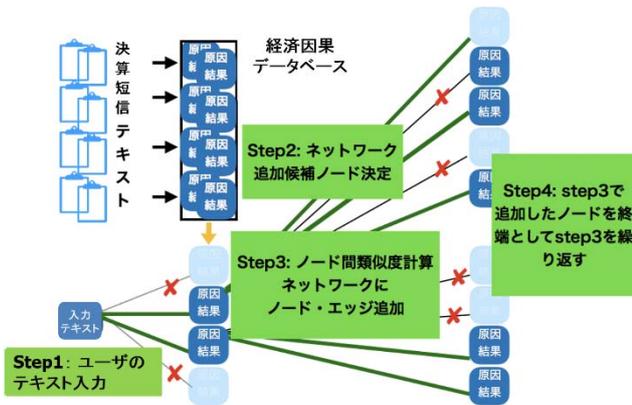


図 1. 因果チェーン構築のアルゴリズム  
([西村 2018] [Nishimura 2018]を基に作成)

## 経済因果チェーン検索システム

上述の因果チェーン構築アルゴリズムを基に、ユーザが提示された因果関係を編集できる機能を加えた経済因果チェーン検索システムを実装した<sup>1</sup>[4]. 以下に本システムの動作する様子を説明する.

最初に開始テキストをユーザが入力する(図 2). その際に、原因から結果への波及効果の検索か結果から原因への要因検索かを指定する. さらに、因果チェーンを構築する対象となる因果関係が発行された期間を限定することも可能である.

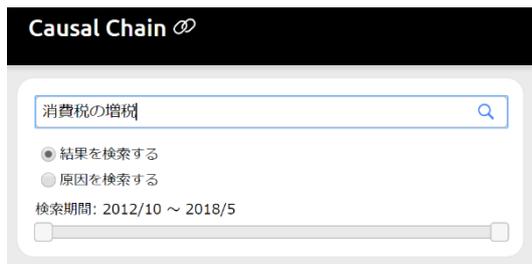


図 2. 開始テキストを入力するテキストボックス

テキストボックスの右にある検索ボタンをクリックすると、開始テキストに連鎖する因果関係を表示する(図 3). デフォルトでは関連性の高い順に 3 個の因果関係を表示する. より多くの因果関係を見なければ、「もっと見る」ボタンをクリックし因果関係ノードの表示を増やすことが出来る. 因果関係の各ノ

ードに対して、ユーザが適切な因果でない判断した場合は、各ノードの右上にある削除ボタンを押して、ノードを削除できる.



図 3. 連鎖する因果関係の表示

各ノードからさらに因果チェーンを伸ばしたい場合は、各ノードの右側にある「>」ボタンをクリックすると、クリックされたノードを終端ノードとして関連する因果関係が追加される(図 4).

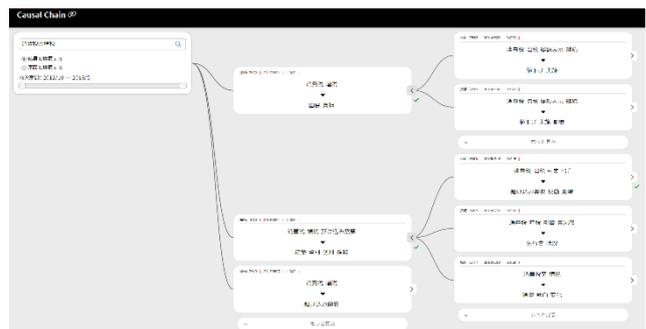


図 4. 因果チェーンの追加

上記の因果チェーンの構築作業を繰り返し、ユーザが必要とする因果チェーンを構築できたら、構築した因果チェーンをファイルに保存することが出来る.

## 経済因果チェーン検索システムの応用例

経済因果チェーン検索システムや因果チェーン検索アルゴリズムを応用したサービスの例を以下に示す.

### 個人投資家向けサービス

一般の個人投資家、特に資産運用を始めたばかりの個人投資家には、資産運用を判断するための情報

<sup>1</sup> 本システムは 2019 年 3 月より東京大学 和泉研究室のサイト (<http://socsim.t.u-tokyo.ac.jp>)にて公開予定である.

が難解であることがある。この難解さの原因の一つとして、自分たちが日常生活で得てきた知識と金融の専門的な知識との間に大きなギャップがあることである。日常的な事象から金融市場動向へは、いくつかの経済事象の因果関係の連鎖が存在する。提案手法により、このギャップを埋めるような知識を提供するサービスを実装できる。

## ニュース内容の波及効果と背景情報の提示

ユーザが日常的に見るニュース記事の中に気になる語句があれば、そこを指定しその語句から派生して関連する経済事象を本手法により提示することができる(図5)。波及効果の中には、ある企業の業績や経営状況に直接関わる事象も含まれるので、ユーザが様々なニュースから関連銘柄を検索するサービスを構築することが可能である。また、逆に指定した語句の要因となり得る事象を検索してユーザに表示することもできる。

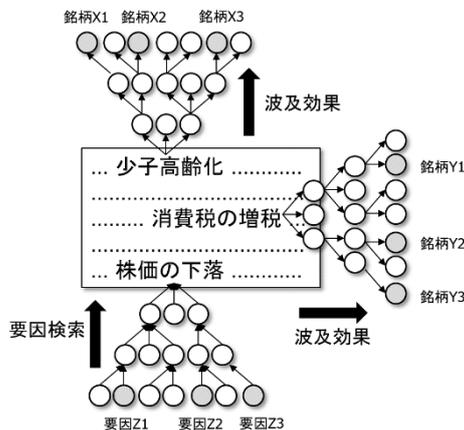


図5. ニュース内容の波及効果と背景情報の提示サービス

## 質問応答システム

金融機関が個人投資家向けに提供する対話エージェントサービスに提案手法を応用可能である。個人投資家があまり金融専門知識を有していない場合、対話システムのエージェントに対して、質問をしていく場面が多くなると考えられる。自分の経験や興味に関連する一般的な話題を切り口にして、関連する経済事象や銘柄を質問してきた場合に、提案手法により関連しうる事象や銘柄と、なぜ関連すると考えられるかを答えることができる(図6)。また、事象を引き起こした要因も返答できる。

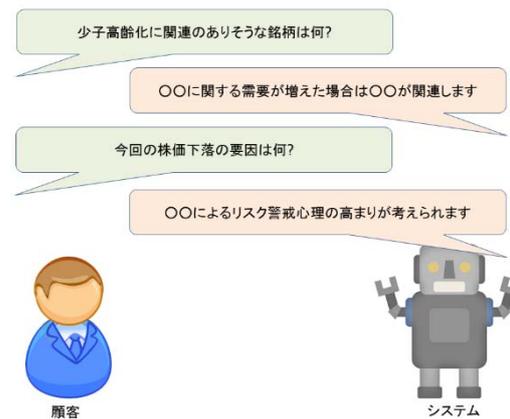


図6. 個人投資家向けの質問応答システム

## 金融実務家向けの業務支援

提案手法により、アナリストや営業担当者など金融機関の様々な部門の実務者の業務支援システムを構築することができる。

## レポート作成支援

金融機関のアナリストは、顧客向けに特定の銘柄や市場全体の動向に関するレポートを定期的に発行する。提案手法により、アナリストがレポートを作成する際のコンテンツを決めることを支援することができる。例えば、ある事象から解説対象の市場に対して何か波及効果がなかったかを検索し、レポートにこの事象を書くべきかどうか決める。また、ある市場の動きに対して、潜在的な要因を検索し、レポートに書くべき要因に漏れがないかどうかをチェックできる。他にも、ある事象Xが別の事象Yを引き起こすとレポートに書いた場合に、事象Xから事象Yへの因果系列を検索して、因果の飛躍がないかどうかチェックすることができる。途中にある因果系列のステップ数が長い場合には、途中の因果の一部をレポートに追記して、読者に理解しやすいようにする。

## セールス支援

上述の個人投資家向けの質問応答システムと同様の機能で、金融機関の営業担当者が顧客にセールスを行う際に、顧客の興味や関心と関連する銘柄を検索することができる。顧客の属性や興味に関連してあらかじめ関連銘柄を検索しておけば、営業活動の支援となり得る。また、顧客からの質問に対しても、上述の質問応答システムで、返答すべき内容の候補を得ることができる。このような対面営業以外でも、オンライン上での資産運用アドバイスで、基本的な相談であれば本手法により自動化を支援することが

できる。

## 多種の因果データベースとの連鎖

決算短信以外のテキストデータから因果関係データベースを構築し、多様な分野の因果データベースを組み合わせることによって、以下のような解析や応用をすることができる。

### 業務報告書・社内文書

各企業には、通常業務において担当者が作成した社内文章が存在する。例えば、金融機関では営業部門や融資部門が対応した顧客に関して、業務報告書や稟議報告書などを作成している。また、アナリストやトレーダーなどの市場の専門家が、作成した相場見通しに関する定期的な分析レポートもある。このような今までの業務で蓄積された社内文章には、有用な業務知識や専門知識が多く含まれおり、大量に集めて解析することによりデータを保有する独自の知識として高い価値を有することがある。例えば、地域の金融機関の業務報告書を機械学習手法で解析し、その地域の詳細な経済活動指標を作成した例がある[5]。同様に、本提案手法を用いて、その企業しか持っていない社内文章から因果データベースを構築し、決算短信などの一般的な文章からの因果データベースと組み合わせれば、その企業の独自知識を活用した新たな因果系列を探索できる。

### 特許文書

金融以外の分野でも、有用な因果データベースを構築できるテキストデータは多数ある。例えば特許文書の中には、特定の技術がどのような効果をもたらすのかという因果関係の情報が多く含まれている。特許文書から構築した因果データベースを用いて、因果チェーンを探索すれば、複数の技術の組み合わせによりどのような効果が期待できるかということを見つめることができる。また、特許文書の因果データベースと経済分野の因果データベースを合わせれば、技術の経済的波及効果や技術に対するニーズを調べることができる。

### ミッシングリンクの発見

上述の経済や技術分野だけでなく、より一般的な分野での因果関係をニューステキストなどから構築し、これらの因果データベースを組み合わせれば、現在は存在していない重要な因果関係を探索することができる。現状  $X$  から開始した波及効果  $\{x_1, x_2, \dots, x_n\}$  を検索する。次に、達成したい状況  $Y$  から因果関係を遡って要因  $\{y_1, y_2, \dots, y_m\}$  を検索する。最後に、 $x_i$  と  $y_j$  の組み合わせについて、 $x_i$  を原因として  $y_j$  が

結果となるような現象や技術がないかを検討してみる。こうすることによって、目標状況  $Y$  を達成するために、現在は存在しないが重要な技術や現象を発見することを支援できる。

## まとめ

本研究では、経済・金融に関わる事象の因果関係を、経済テキストデータから抽出したデータベースから連鎖的に検索するシステムの紹介をした。本システムにより、ユーザが入力したイベントからの経済的な波及効果を推論したり、ニュース記事からの因果チェーンをたどった関連銘柄を提示したりするなどのサービス応用のアイデアを紹介した。

## 謝辞

本システムを実装するにあたって、日名 洋平 氏と松田 健児 氏に多大な助力をいただいた。ここに深謝の意を表す。

## 参考文献

- [1] 坂地 泰紀, 酒井 浩之, 増山 茂: 決算短信 pdf から原因・結果表現の抽出, 電子情報通信学会論文誌 D, vol. 98, no.5, pp.811-822, 2015.
- [2] 西村 弘平, 坂地 泰紀, 和泉 潔: ベクトル表現を用いた因果関係連鎖の抽出, 人工知能学会 第 20 回金融情報学研究会, pp.50-53, 2018 年 3 月.
- [3] K. Nishumura, H. Sakaji, K. Izumi: Creation of Causal Relation Network using Semantic Similarity, 第 32 回人工知能学会全国大会, p. 1P104, 2018 年 6 月.
- [4] 坂地 泰紀, 和泉 潔, 松島 裕康: 金融テキストマイニングの基づいた投資家支援プラットフォームの開発, 人工知能学会 第 21 回金融情報学研究会, 2018 年 10 月.
- [5] 坂地 泰紀, 和泉 潔, 松島 裕康, 川瀬 和哉, 林 寛, 接触履歴を用いた地域景況インデックスの自動生成, 日本知能情報ファジィ学会誌 (to be appeared)

# 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

## Trading System using Deep Reinforcement Learning

常井 祥太

穴田 一

Shota Tokoi

Hajime Anada

東京都市大学大学院工学研究科

Graduate School of Engineering, Tokyo City University

**Abstract:** In recent years, investment strategies using artificial intelligence have attracted a significant amount of research attention. However, it is difficult to construct an efficient investment strategy using artificial intelligence owing to the variable factors in market prices. Therefore, this study aims to focus on a trading method called the NT ratio transaction to reduce the number of price-variable factors. This transaction is an arbitrage transaction, which utilizes the difference in the price movements between Nikkei 225 futures and TOPIX futures. These futures generally exhibit similar price movements and even if the price differences expand, they tend to return to their original separation. Using this transaction, we can target profits from this price difference while offsetting a considerable number of price-variable factors. Therefore, in this study, we construct a model to acquire an investment strategy based on NT ratio transactions via deep reinforcement learning and confirm the effectiveness of this model.

## 1. はじめに

近年、人工知能に関する研究が活発に行われており、例として、強化学習[1]などを取り入れた将棋 AI である AlphaGo が人間のトップ棋士を破る大きな成果を残している。そのような中で、金融分野でも人工知能を用いた投資戦略の研究が行われている。松井らは複利型強化学習という新たな強化学習の枠組みを提案した。複利型強化学習とは、試行錯誤を通じてエージェントが将来獲得する報酬ではなく、複利式のリターン（得た利益を掛け金に上乗せして得るリターン）を最大化する行動規則を学習する枠組みである[2]。また、彼らは複利型強化学習における行動価値関数をニューラル・ネットワークで表した複利型深層強化学習を提案した。この手法で彼らは、日本国債の週次取引における行動規則を学習し、利益率が向上していく様子を確認した[3]。しかし、最終的な利益率を見ると、学習が十分であるとは言い難い。これは国債や株価などには価格変動要因がかなり多く存在し、それらを十分に考慮できていないことが原因であると考えられる。しかし、これらは各国のニュースによる変動への影響など定量化が困難なものが多い。そこで、本研究では価格変動要因を減らすため、NT 倍率取引という取引手法に着目する。NT 倍率取引とは、日経 225 先物と TOPIX 先物の値動きの違いを利用した取引である。これらのよ

うな相関性の強い 2 つの金融商品に対して「買い」と「売り」をそれぞれ同時に行うことにより、価格の変動要因の大部分が相殺できるため、2 つの価格差のみに着目した取引が可能になる。また、松井らの手法では状態変数が 2 つと少なく、多数の状態変数を扱える深層強化学習の利点を活かし切れていない。そのため、状態変数を増やすことで、現在の状況を適切に捉えた上で、より良い投資行動を行えるようになるのではないかと考えた。さらに、通常の強化学習では、行動する度に報酬量を決定し付与するが、金融取引において、買う、売るなどの行動の良し悪しをすぐさま決定することは大変困難である。そこで、ポジションを取得してから保持し、解消するまでの行動に関する報酬を、ポジションを解消した時に一括で決定し、付与するよう変更を加えた。以上のことを踏まえた、NT 倍率取引における投資戦略を、深層強化学習によって獲得する数理モデルを構築し、その有用性を確認した。

## 2. 提案手法

本研究はコンピュータシミュレーションによって行う。コンピュータ上につくられた仮想的な投資家が、1 日 1 回市場の状態を観測し、その状態におけるそれぞれの投資行動の価値（Q 値）を推測する。その価値が高い行動を選択、実行し、結果が良ければその行動に報酬を与えて、同じ状態においてその

行動をとりやすくする。この Q 値の推測はニューラル・ネットワークを用いて行い、報酬に応じてその重みを変えることを繰り返して学習を進めていく。

## 2.1 既存手法からの変更点

本研究では、松井らの手法[3]をベースに総資産の最大化を目的として、以下の点を変更した。

### (1) 取引手法

松井らの手法では、日本国債の週次取引に対する行動規則を学習した。しかし、国債には多くの価格変動要因が存在し、適切な行動選択を困難にしている。これらの変動要因をすべて取り入れて行動を選択することは不可能である上、多くの場合取り入れていない要因からも大きな影響を受けるため、安定した学習ができなくなってしまう。そこで、まず「考慮しなければならない価格変動要因を減らし、状況を簡略化すること」を考えた。具体的には、相関性が強く、価格差が拡大しても元に戻りやすいような2つの金融商品に対して、「買い」と「売り」をそれぞれ同時に行う取引を考える。これにより価格変動要因の大部分を相殺可能である。このような相関が強い金融商品として、日経 225 先物と TOPIX 先物がある。この2銘柄に対して「買い」と「売り」をそれぞれ同時に行う取引を NT 倍率取引という。日経 225 先物と TOPIX 先物の価格の推移を図 1 に示す。



図 1：日経 225 先物と TOPIX 先物の価格推移。

図 1 の横軸は期間、縦軸は価格である。赤い折れ線が日経 225 先物であり、青い折れ線が TOPIX 先物である。日経平均株価と TOPIX には約 10 倍の違いがあるため、この図では TOPIX に 10 をかけたものをプロットしている。これを見ると、変動の仕方がかなり似通っていることが分かる。これは、日経平均株価と TOPIX がどちらも東証一部上場企業の株価や時価総額から計算される指標だからであり、変動の仕方がわずかに異なるのは計算に用

いられている企業や、株価か時価総額かの違いによるものである。このように、定量化が困難な各国のニュースなどの影響の大部分はどちらも等しく受けており、2 銘柄の価格の違いに着目した投資判断を行うことによって、価格変動要因の大部分が相殺された状態での取引が可能になる。そこで本研究では、NT 倍率取引を取引手法として選択した。

### (2) 学習方法

松井らの手法では、取引量を調節しながら利益率の複利効果を最大化するため、投資比率と複利リターン[2]を考慮した学習を行っている。しかし、本研究ではモデルを単純化するため、取引を 1 単位ずつの売買もしくはポジションの解消に制限した。

### (3) 行動

本研究では行動として「1 単位 NT 買い(日経 225 先物買い, TOPIX 先物売り)」、「1 単位 NT 売り(TOPIX 先物買い, 日経 225 先物売り)」、「NT 買いポジション解消」、「NT 売りポジション解消」、「何もしない」の 5 つとする。ここで、日経 225 先物の最低取引単位(1 単位)は日経平均株価の 1,000 倍、TOPIX 先物の最低取引単位(1 単位)は TOPIX の 10,000 倍である。NT 買い(売り)ポジションとは、日経 225 先物を 1 単位以上保持(空売り)、TOPIX 先物を 1 単位以上空売り(保持)している状態を指し、それを解消することはすべての金融商品を現金化することを指す。

### (4) 状態

松井らの手法では、状態変数として終値とその標準偏差を相対化した値を用いている。これは金融商品の価格などは大きく変動するため、そのまま状態として用いると、体験したことのない未知の状態に陥りやすくなってしまふからである。時刻  $t$  の状態変数  $v_t$  を相対化した値  $O_t$  は以下のように求める。

$$O_t = \frac{v_t - \mu_{t,k}}{4\sigma_{t,k}} \quad (1)$$

ここで、 $\mu_{t,k}$  は時刻  $t$  から過去  $k$  期間のデータから求めた移動平均、 $\sigma_{t,k}$  は同様に求めた移動標準偏差を表す。これにより、 $[\mu_{t,k} - 4\sigma_{t,k}, \mu_{t,k} + 4\sigma_{t,k}]$  の範囲を  $[-1, 1]$  の範囲に正規化できる。松井らは終値とその移動標準偏差をそれぞれ相対化した 2 つの状態変数を用いている。

本研究では、深層強化学習の多数の状態変数を扱えるという利点を活かし、より状況を適切に捉えるため、状態変数の数を 10 に増やす。まず、TOPIX 先物の終値に対する日経 225 先物の終値の

割合である NT 倍率と、その移動標準偏差を相対化した値を状態変数とした。この時、移動平均を求める期間  $k$  は短期、中期、長期の 3 パターン設定し、それぞれに対して相対化を行う。NT 倍率は、松井らの終値と同様に現在の市場の動向を表す指標として採用している。次に利益確定を学習するために「含み損益」を加えた。  $t$  日目の含み損益  $prof_t$  は以下のように定義する。

$$prof_t = \frac{(P_t^N - P_{t-e}^N)S_t^N + (P_t^T - P_{t-e}^T)S_t^T}{A_0} \quad (2)$$

ここで、  $P_t^N$  は  $t$  日目の  $N$  (日経 225 先物) の価格、  $P_t^T$  は  $t$  日目の  $T$  (TOPIX 先物) の価格、  $e$  はポジションをとってからの日数である。よって、  $P_{t-e}^N$  はポジションをとった時の価格になる。  $S_t^N$  は  $t$  日目の  $N$  (日経 225 先物) のストック数であり、保有している分を正の値、空売りしている分を負の値で表す。  $A_0$  は初期資産である。これを状態変数として取り入れることで、今ポジションを解消したらどのくらい利益が得られるかを把握することができる。次に「“NT 買いポジションをとってから最大の NT 倍率”と“現在の NT 倍率”の差」と「“現在の NT 倍率”と“NT 売りポジションをとってから最低 NT 倍率”の差」をそれぞれ「機会損失幅 (NT 買いポジション)」と「機会損失幅 (NT 売りポジション)」として定義し、状態変数として導入する。これらは、最大利益を獲得できる時点から NT 倍率がどのくらい変わってしまったかを把握するための状態変数である。そして、現在のポジションを把握するための「現在のポジション」を加えた 10 個の状態変数を用いて学習を行う。

#### (5) 報酬

松井らの手法では、複利リターンを最大化するため、利益率  $R$ 、投資比率  $f$  の時の gross 利益率 (利益率に 1 を加えたもの、つまりは資産の変化前に対する変化後の割合である) の対数  $\log(1 + Rf)$  を報酬としている。しかし、本研究では複利リターンを考慮しない。

また、松井らの手法ではとった行動に対してすぐに報酬を決めて与えているが、金融取引において行動の良し悪しをすぐに決めるのは大変困難である。そこで本研究では、ポジションを取得してから解消するまでの全ての行動に対する報酬を、ポジションを解消した後一括で決定し、付与する。このとき付与量はポジションの状態によって異なるように設定した。買い(売り)ポジションの取得時と保持時には、「最大(最低) NT 倍率」と「現在の NT 倍率」の差の絶対値を報酬とする。この

とき、最大(最低) NT 倍率の時点より前の行動に関してはそのまま正の報酬、後の行動に関しては  $-1$  をかけて負の報酬とする。これにより、前者は「現在の NT 倍率からこのポジション中に NT 倍率がどれだけ上がる(下がる)か」、後者は「最大で稼げる NT 倍率からどのくらい下がって(上がった)しまったか」を考慮した報酬を表す。買い(売り)ポジションの解消時には「“現在の NT 倍率”と“ポジション取得時の NT 倍率”の差(“ポジション取得時の NT 倍率”と“現在の NT 倍率”の差)」を報酬とする。これは「ポジションを取得した時の NT 倍率からどれだけ上がった(下がった)か」、つまり利益をどれだけ出せたかに応じた報酬であることを表す。

さらに、持っていないポジションを解消しようとした際に定数  $penalty$  ( $penalty < 0$ ) の報酬を与える。例えば、NT 買いポジションをとっている時に NT 売りポジションを解消しようとした時などである。このような行動をとらないように負の報酬を設定した。

## 2.2 提案手法の流れ

提案手法での学習の流れを以下で述べる。

- ① 初期化  
行動価値関数を表すニューラル・ネットワークを初期化する。
- ② 取引とデータ収集  
行動価値関数から得られる行動規則に従って取引を行い、データ(状態変数ベクトル  $X$ 、行動  $a$ 、報酬  $r$ 、次の状態を表す状態変数ベクトル  $X'$ ) を収集する。収集したデータは *Replay Buffer* に保存するが、この時、ポジションの状態に応じて異なる処理を行う。ポジションを保持していないときに「何もしない」を選択した場合は報酬  $r = 0$  とし、得られたデータを即座に *Replay Buffer* に加える。ポジションを取得した時から解消する時までのデータは即座には報酬を決めずに、一旦 *Temp List* に保存する。これらのデータは、ポジションを解消した時に報酬をまとめて決定し、*Replay Buffer* に保存する。その後、*Temp List* 内のデータをすべて削除する。  
この際の行動選択には、 $\epsilon$  の確率でランダムに行動し、それ以外は  $Q$  値の一番高い行動を選択する  $\epsilon$ -greedy 法を用いる。これを  $M$  回繰り返す。
- ③ ニューラル・ネットワークの更新  
*Replay Buffer* 内のデータからランダムサンプリングにより、 $m$  個取り出してそれぞれ  $Q$  値を計算し、それらを教師データとして行動価値関数を表すニューラル・ネットワークを更新する。ここで、

$t$  日目の状態  $X$  での行動  $a$  に対する  $Q$  値, つまり,  $X$  を入力した時の望ましい出力  $q_t$  は以下のように求める.

$$q_t \leftarrow r + \gamma \max_a Q(X', a') \quad (3)$$

ここで,  $r$  は 2.1 で決めた報酬,  $\gamma$  は将来の報酬に対する割引率である. これにより, 今回の行動で得られた報酬と, 次の状態での最大価値を持つ行動の  $Q$  値を割り引いたものの和を望ましい出力とする.

④ 終了判定

②~③を任意の回数繰り返す.

テスト時には, 行動価値関数から得られる行動規則に従い, テスト期間の取引を行う. この際, 行動選択には, 常に  $Q$  値の一番高い行動を選択する greedy 法を用いる.

### 3. 実験

実験は日経 225 先物と TOPIX 先物の日次取引を対象として行う. 学習期間は 2009/3/4~2015/12/31 で 1682 日分, テスト期間は 2016/1/4~2017/12/29 で 506 日分のデータを用いた. また, 過去の実験より, NT 倍率が長期的に上昇トレンドであることから, 単に「1 単位 NT 買い (日経 225 先物買い, TOPIX 先物売り) をし続けてしまう」という局所解に陥ってしまったという問題があった. そこで本実験では, 学習期間の NT 倍率の時系列データからトレンドを除去する. 原系列とトレンド除去後の NT 倍率の推移を図 2 に示す.

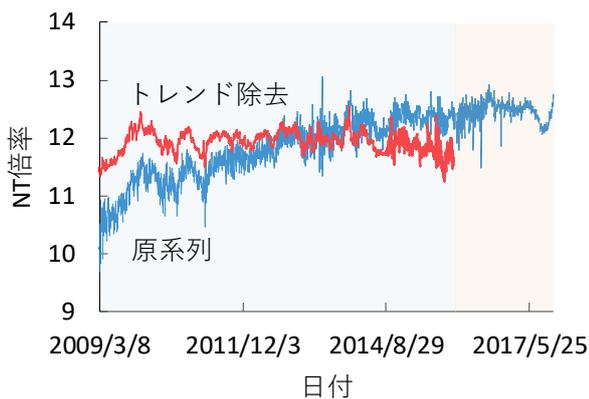


図 2 : NT 倍率の推移.

図 2 の横軸は日付, 縦軸は NT 倍率である. 青い折れ線は NT 倍率の原系列, 赤い折れ線はトレンド除去後の NT 倍率を表している. 青背景の部分が学習期間, 橙背景の部分がテスト期間である. 取引は 1 日 1 回, 前日の終値を観測し, 当日の始値で行う.

学習期間での取引をすべて終わるまでを 1 エピソードと定義し, 1000 エピソードを終える度にテスト期間の取引を行い, それを終えたらまた学習期間の取引を行う.

本研究で用いる深層強化学習のモデルは Deep Q-Network である. ここで用いられるニューラル・ネットワークの中間層は 2 つで, そのユニット数は入力側から 100, 25 である. 重みは Xavier の初期値を用い, 活性化関数は, 中間層から出力層の間が線形結合, それ以外はランプ関数 (ReLU) とした. 最適化手法は Adam, 学習時のニューラル・ネットワークの更新間隔は  $M = 100$ , ランダムサンプリング数は  $m = 20$  である.

学習期間の行動選択方法は  $\epsilon$ -greedy 選択, テスト期間は greedy 選択とした. ランダムな行動を選ぶ確率  $\epsilon$  は 0 エピソード時には 1.00 とし, 50,000 エピソードかけて 0.10 まで線形に低下していくように設定した.  $Q$  値更新時の将来報酬の割引率は  $\gamma = 0.95$  とした.

状態変数の相対化に用いる期間は  $k = 5, 25, 75$ , 違反行動をとった時の報酬は  $penalty = -0.1$  とし, 初期資産は  $A_0 = 10,000,000$  で実験を行った.

### 4. 結果と考察

まず, 学習期間の最終総資産の推移を図 3 に示す.

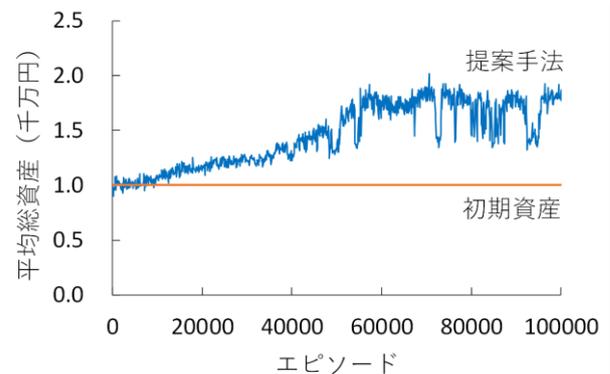


図 3 : 学習期間の平均最終総資産の推移.

図 3 は横軸がエピソード, 縦軸が総資産である. 青い折れ線は, 1 エピソードの終わり時点での総資産を 100 エピソード毎に平均し, プロットしたものである. また, 橙色の直線は初期資産である. これを見ると提案手法は, ゆるやかに総資産を伸ばし, 最終的にはかなり高い値で収束していることが分かる.

次に、テスト期間の最終総資産の推移を図 4 に示す。

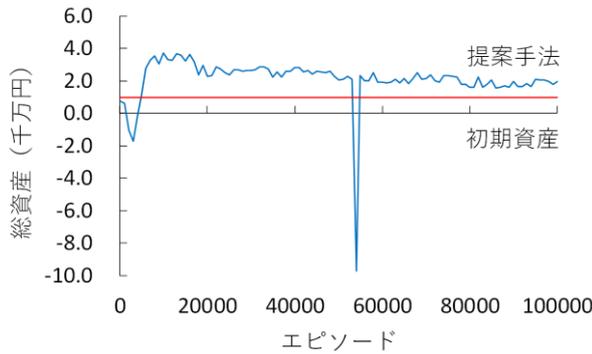


図 4：テスト期間の最終総資産の推移。

図 4 は横軸がエピソード、縦軸が総資産である。青い折れ線は、テスト期間の取引結果の最終総資産をプロットしたものである。また、赤色の直線は初期資産である。提案手法による最終総資産は、序盤落ち込んだ後、急速に上昇し、その後は徐々に落ちていく様子が観測された。また、中盤には急激に最終総資産が落ち込んでいるが、この原因はまだ分かっていない。

次に、本実験における最終エピソードである 10 万エピソード時にどんな戦略をとっているのかについて分析する。まずはエピソード中の総資産の推移を確認する。10 万エピソード時のテスト期間 1 試行中の総資産の推移を図 5 に示す。

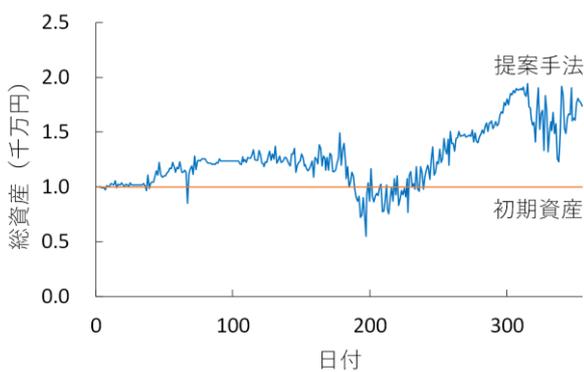


図 5：テスト期間 1 試行中の総資産の推移。

図 5 は横軸が日付、縦軸が総資産である。青い折れ線は、10 万エピソード時のテスト期間 1 試行中の総資産を 1 日毎にプロットしたものである。また、橙色の直線は初期資産である。これを見ると、最終的には初期資産よりも高い値で取引を終えているが、中盤に初期資産を下回る部分がある。安定して稼げているとは言い難い。

次に、どのような取引を行っているかを先程同様 10 万エピソード時のテスト期間 1 試行の結果を用いて分析する。具体的には、NT 買いストック数（日経ストック数）と NT 倍率の推移を見て、NT 倍率がどうなっている時にどのようなポジションをとっているのかを確認する。図 6 は NT 買いストック数と NT 倍率の推移である。

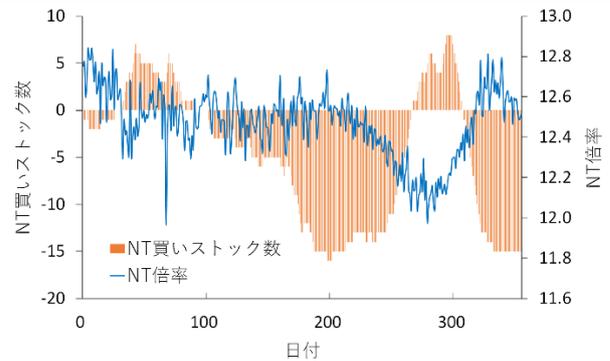


図 6：NT 買いストック数と NT 倍率の関係。

図 6 は横軸が日付、左軸が NT 買いストック数、右軸が NT 倍率である。橙色の棒グラフが NT 買いストック数、青色の折れ線が NT 倍率である。NT 買いストック数が正のときは、NT 買いポジションをとっていることを表し、NT 買いストック数が負のときは、NT 売りポジションをとっていることを表す。振る舞いを見ると、NT 倍率が下がった時には NT 買いストック数は負の値になっており、逆に NT 倍率が上がった時には NT 買いストック数は正の値になった。このような「価格が上がると思われるときに買い、上がりきったところで売る（価格が下がると思われるときに売り、下がりきったところで買う）」戦略は「順張り」といい、金融取引で一般的に使われる戦略である。これは、報酬により、ポジション取得時点から NT 倍率がどのくらい変化するか（どのくらい利益を出せるか）を考慮していることが効いていると考えられる。これによって「『上がると思われるときに買いポジションをとる』または、『下がると思われるときに売りポジションをとる』という行動規則が創出されている。また、状態変数の「機会損失幅」があることにより、「一番含み益を出している時点から NT 倍率がどのくらい変化しているか」の報酬を、状態をしっかりと把握させた状態で与えることができている。これにより、「『買いポジションをとっているときに NT 倍率が下がりそうになったら買いポジションを解消する』または、『売りポジションをとっているときに NT 倍率が上がりそうになったら売りポジションを解消する』という利益確定

の動きが創出できている。

しかし、行動の中に「NT 買いポジション解消」、  
「NT 売りポジション解消」があるにも関わらず、NT  
買いストック数は瞬時に 0 になることはなく、1 単  
位ずつ変化している。これはポジションを解消すべ  
きタイミングで「NT 買い」または「NT 売り」の行  
動をとって1単位ずつポジションを崩しており、「NT  
買いポジション解消」、「NT 売りポジション解消」の  
行動を上手く使えていないことを表している。原因  
としては、1つずつポジションを崩してポジション  
を解消した場合と、一気に解消した場合で報酬量が  
変わらないことが考えられる。

## 5. 今後の課題

まず、「買いポジション解消」と「売りポジション  
の解消」の2つの行動を有効に活用できるようにす  
ることが挙げられる。ポジションを1単位ずつ崩し  
ていくのではなく一気に解消することで、素早い取  
引が可能になると考えられる。また、テスト期間の  
結果(図4)の総資産が急落している問題についての  
分析を行う必要がある。

そして最後に、最新手法の利用を検討している。  
現在は Deep Q-Network という学習方法を用いてい  
るが、A3C (Asynchronous Advantage Actor-Critic) [4]  
という Deep Q-Network を発展させたモデルが開発  
されている。このモデルには、Asynchronous (複数の  
エージェントを同時に動かし、個々の経験を集めて  
学習)、Advantage (1ステップ先ではなく、数ステッ  
プ先の報酬を考慮) などの特徴がある。これを用い  
ることで学習時に1つ先の報酬だけでなく、もう少  
し先の報酬も考慮できるようになる他、LSTM[5]な  
どの時系列データの扱いに長けたニューラル・ネッ  
トワークの使用が可能になる。このような理由から、  
A3C の導入を検討している。

## 参考文献

- [1] Richard S. Sutton and Andrew G. Barto : 強化学習  
(三上貞芳・皆川雅章 訳). 森北出版(2000)
- [2] 松井藤五郎, 後藤卓, 和泉潔, 陳ユ : 複利型強化学習  
における投資比率の最適化, 人工知能学会論文誌,  
Vol.28, No.3, pp. 267-272 (2013)
- [3] 松井藤五郎, 片桐雅浩 : 金融取引戦略獲得のための複  
利型深層強化学習, 第 16 回人工知能学会金融情報学  
研究会(SIG-FIN), SIG-FIN-016-01 (2016)
- [4] Volodymyr Mnih, Adrià Puigdomènech Badia, Mehdi  
Mirza, Alex Graves, Timothy P. Lillicrap, Tim Harley,  
David Silver, Koray Kavukcuoglu : Asynchronous  
Methods for Deep Reinforcement Learning, In  
Proceedings of the 33rd International Conference on

Machine Learning (ICML), pp. 1928–1937 (2016)

- [5] Sepp Hochreiter, Jürgen Schmidhuber : Long Short-Term  
Memory, Neural computation, 9(8), pp. 1735–1780 (1997)

# LSTM による時系列予測と株式投資戦略への応用

## Time Series Prediction with LSTM Networks and its Application for Investment Strategy

松本 健<sup>1</sup> 牧本 直樹<sup>1</sup>

Ken Matsumoto<sup>1</sup> and Naoki Makimoto<sup>1</sup>

<sup>1</sup>筑波大学大学院ビジネス科学研究科

<sup>1</sup>Graduate School of Business Sciences, University of Tsukuba

**Abstract:** Researches for financial time series in stock or foreign exchange markets, have been one of traditional themes of financial market analysis. Statistical model approaches such as ARMA and GARCH were mainstream of conventional analysis. However, it is difficult to understand and predict financial time series structures, which are generally characterized by high noise level and low autocorrelation. Meanwhile, researches to capture the structure by artificial intelligence has been increasing in recent years. In particular, Long Short-Term Memory (LSTM), which can capture time series structure, is already widely used in the field of natural language processing and speech recognition. Therefore, in this study, we investigated the model performance in each TOPIX core30 constituent stock by using logistics regression (LOG), random forest (RAF), gradient boosting (GBT), support vector machine (SVM), and LSTM. The performance was evaluated by metrics such as prediction accuracy, F1 measure, AUC, and return. As a result, LSTM showed the best performance in the models. Moreover, we discussed the effectiveness of the stock market neutral strategy by applying the above prediction models. 10-quantile portfolios using the predicted probability outputted by the model, remarks higher accuracy and returns than individual stock trading in all models. Furthermore, LSTM outperformed the others and it is consistent with the result of S&P500 constituent stocks analysis.

## 1. 序論

株式市場や外国為替市場等における金融時系列データを分析対象とする研究は、金融市場分析の伝統的なテーマの1つである。しかしノイズが支配的である金融資産のリターン系列は、一般に自己相関が低いという特徴があり、時系列構造の理解とその予測は難しい。時系列解析は統計モデルによるアプローチが主流であり、金融時系列の実証分析は既に膨大な研究例がある。線形モデルである ARMA やボラティリティ変動モデルである GARCH や確率的ボラティリティモデル [1]、さらにレジームスイッチングモデル [2]等が提案されている。ただし、何れにおいても時系列の構造理解が目的であるため、株式リターンの予測精度は決して高いとは言えない。

一方、人工知能のアプローチで時系列構造を捉える研究は近年増加傾向にある。ロジスティック回帰やランダムフォレスト、勾配ブースティング、サポートベクターマシンといった機械学習モデルやディ

ープニューラルネットワークモデルが時系列解析に応用されつつある。特に時系列データを取り扱うことができるリカレントニューラルネットワーク型の LSTM (Long Short-Term Memory) は、既に自然言語処理や音声認識の分野において、単語列や音波が持つ特徴量を捉えるために有効活用されており、その認識精度の向上に大きく貢献している。

LSTM と他モデルによる金融時系列予測の研究例として、ここでは Fischer and Krauss [3] を取り上げる。S&P500 を構成する 500 銘柄の日次リターンを LSTM、ディープニューラルネットワーク、ランダムフォレスト、ロジスティック回帰のモデルで予測する実験を行っている。構成銘柄毎に、過去の日次リターン 240 日分から 1 日先の超過リターンの正負を予測する 2 値分類モデルを構築している。さらにその分類モデルから算出される予測確率から、分位ポートフォリオを構築して、パフォーマンスを比較している。結果として、正解率や実現リターン、シャープレシオといった指標において、LSTM モデルが他のモデ

ルをアウトパフォームすることを報告している。

このように LSTM の有効性が示されつつある一方で、未だ金融時系列データの実証研究例が十分にあるとは言えず、どの予測モデルが一番有効であるかというコンセンサスは形成されていない状況にある。そこで本研究では、TOPIX core30 構成銘柄の日次時系列データを対象とした LSTM を含む複数のリターン予測モデルを構築し、そのパフォーマンスを評価する。また、予測モデルを活用した株式投資戦略を立案し、その有効性を議論する。

## 2. 分析データ

本研究では 2017 年 10 月時点で編成されていた TOPIX Core30 の構成銘柄を対象とした分析を行う。TOPIX Core30 は、TOPIX ニューインデックスシリーズの 1 つで、東京証券取引所の市場第一部全銘柄の内、時価総額と流動性の特に高い 30 銘柄で構成された株価指数を指す。30 銘柄の日次リターン(2009 年から 2017 年までの約 2000 日分)を分析対象とした。

予測モデルの正解ラベルは各個別銘柄の対ベンチマーク超過リターンの正負  $B_{t+1}^s$  と設定する。個別銘柄  $s$  の株価から算出される対数差リターン系列を

$$R_t^s = \log\left(\frac{P_t^s}{P_{t-1}^s}\right) \quad (1)$$

と定義すると、個別銘柄の対ベンチマーク超過リターンは、個別銘柄とインデックス指標のリターン系列の差で計算できる。インデックス指標を TOPIX 株価指数とすると、1 期先の超過リターンとその正負は、

$$y_{t+1}^s = R_{t+1}^s - R_{t+1}^{TOPIX} \quad (2)$$

$$B_{t+1}^s = \begin{cases} 0 & \text{if } y_{t+1}^s < 0 \\ 1 & \text{if } y_{t+1}^s \geq 0 \end{cases} \quad (3)$$

となる。次に個別銘柄の超過リターンを予測するための特徴ベクトルとしてヒストリカルデータを用意する。過去の時点  $t - m$  との累積日次リターンを

$$CR_{t,m}^s = \log\left(\frac{P_t^s}{P_{t-m}^s}\right) \quad (4)$$

と定義する。このとき個別銘柄と TOPIX 株価指数それぞれの過去 1 年間 (240 日) 以内の累積日次リターン  $CR_{t,m}^s, CR_{t,m}^{TOPIX}$  を特徴ベクトルとした。なお各特徴ベクトルは最大 240 時点分を設定可能であるが、Krauss et. al, [4] の変数重要度を参考に 15 時点として、時点  $m$  を以下のように設定した。

$$m \in \{1, 2, \dots, 9, 10, 20, 40, 60, 120, 240\} \quad (5)$$

## 3. 予測モデル

LSTM モデルと比較検証するために、他の機械学習モデルも併せて分析する。表 1 に利用するモデルとその略称名を記す。今後のモデル名は略称名で統一する。

表 1 予測モデル

略称名	モデル
LOG	正則化ロジスティック回帰
RAF	ランダムフォレスト分類器
GBT	アダブースティング決定木
SVM	サポートベクターマシン分類器
LSTM	LSTM 分類器

過学習の防止と汎化性能向上のために各予測モデルのハイパーパラメータチューニングを行った。データセットをトレーニングデータ、バリデーションデータ、テストデータの 3 種類に分別した。テストデータについては、モデルの最終的な精度評価用として直近の時系列データ 20% を利用する。残りの 80% のデータはランダムシャッフルと層化抽出法によりトレーニングデータ 60% とバリデーションデータ 20% に分割した。ある 1 組のハイパーパラメータ群を所与とした場合にトレーニングデータでモデルのパラメータを学習し、その評価をバリデーションデータで行うことで学習済みモデルを選定した。

なおハイパーパラメータの探索は、グリッドサーチやランダムサーチといった方法論が確立されている。しかしグリッドサーチは、ハイパーパラメータ空間を全探索できるが、ハイパーパラメータの次元数に学習時間が指数関数的に増加するため、ディープラーニングでは現実的な方法論とは言えない。またランダムサーチは現実的な試行回数で探索を打ち切れるが、ハイパーパラメータの大域での最適値が探索できるとは限らない。そこで本研究ではベイズ最適化手法の 1 つである SMBO (Sequential Model-based Global Optimization) のアルゴリズムを採用することとした [5]。

## 4. 個別銘柄のリターン予測

各モデルのパフォーマンスは 30 銘柄毎の予測精度と実現リターンの観点から評価した。予測精度については、予測ラベルをラベル 1 に属する確率  $\hat{P}(B_{t+1}^s = 1)$  と境界値 0.5 より

$$\hat{B}_{t+1}^s = \begin{cases} 0 & \text{if } \hat{P}(B_{t+1}^s = 1) < 0.5 \\ 1 & \text{if } \hat{P}(B_{t+1}^s = 1) \geq 0.5 \end{cases} \quad (6)$$

として正解率、F1 値、AUC を評価尺度とする。また

実現リターンは予測ラベルが 1 のときロングポジション、予測値が 0 のときショートポジションを取った場合のリターン  $\hat{R}_{t+1}^s$  を

$$\hat{R}_{t+1}^s = \hat{B}_{t+1}^s R_{t+1}^s - (1 - \hat{B}_{t+1}^s) R_{t+1}^s \quad (7)$$

として算出する。ここで第 1 項はロングポジションのリターン、第 2 項はショートポジションのリターンを表す。

各評価指標の内、30 銘柄毎の正解率と実現リターンの結果をそれぞれ図 1 と図 2 に示す。30 銘柄の平均正解率は LSTM が最も良い水準にあり、次いで GBT、SVM、RAF が並び、LOG が最も水準が低い結果となった。正解率の標準偏差については GBT と LSTM が低いため、個別銘柄に因らず、安定した予測結果が得られていると言える。また実現リターンにおいても正解率の順位と一致する形で LSTM が最も良いパフォーマンスが得られた。また各銘柄の実現リターンの分散についても低水準となっている。

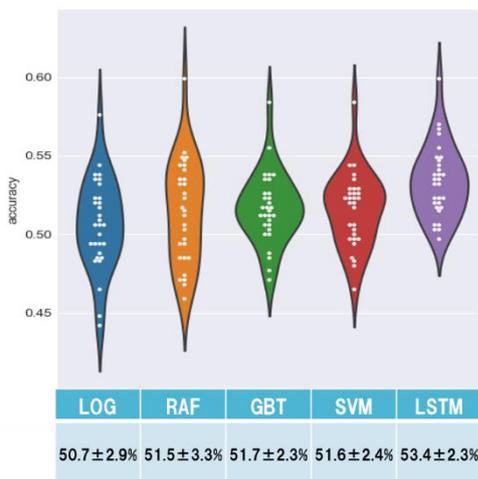


図 1 30 銘柄分の正解率の比較

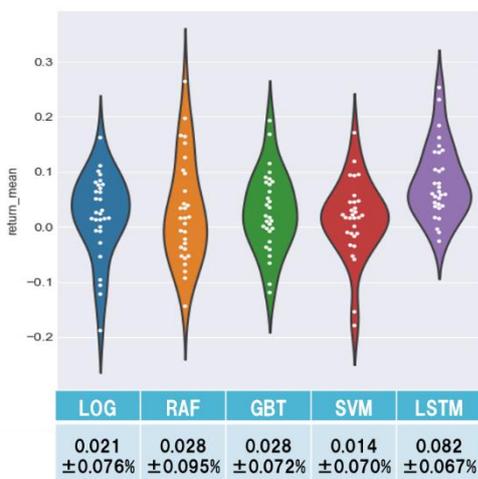


図 2 30 銘柄分のリターンの比較

これらの正解率と実現リターンは、式(6)のように予想確率  $\hat{P}(B_{t+1}^s = 1)$  が、固定された境界値 0.5 を超えるか否かでポジションを取った結果となっている。そのため、例えば予測確率が 51%である場合と 100%である場合を等価に取り扱っており、予測モデルの出力結果を最大限活用できているとは言い難い。そこで次章では、予測確率の大きさを踏まえた投資戦略を検討する。

## 5. 分位ポートフォリオへの応用

本研究で利用する予測モデルは、日次リターン予測かつ超過リターンの正負予測という特性を踏まえると、長期資産運用を目的とした一般的な資産運用より、短期の絶対収益型運用スタイルに親和性が高い。そこで各モデルの予測確率を利用した分位ポートフォリオを考える。各 30 銘柄を予測確率  $\hat{P}(B_{t+1}^s = 1)$  の昇順に並べ直し、この銘柄群から十分位ポートフォリオを構築する。任意の分位数を  $k$  とすると、予測確率が低い第  $k$  十分位までをショートポジションを、予測確率が高い第  $k$  十分位までをロングポジションを取った場合のパフォーマンスを調べる。

例えば  $k = 1$  のとき、第 1 十分位(3 銘柄)をショートポジション、第 10 十分位(3 銘柄)をロングポジションとするため、銘柄群の内 20% が取引対象銘柄となる。  $k = 5$  の場合では、第 1~第 5 十分位までをショートポジション、第 6~第 10 十分位までをロングポジションとなるため、30 銘柄すべてが投資対象となる。個々のロング・ショートポジションはすべてダラーニュートラルとなるように 1 単位ずつ保有するが、個別銘柄の分析結果と比較可能にするため  $1/2k$  倍して単位を揃えた。また本分析では各売買に関わる手数料は考慮しない。

なおこの分位ポートフォリオは、投資戦略の中でも株式ダブルアルファ・ダラーニュートラル戦略に該当する。相対的な価格上昇が見込まれる銘柄のロングポジションと上昇が見込まれない銘柄のショートポジションを保有することで、出来る限り市場の影響を排除して、両ポジションのアルファの獲得を目指す。

各予測モデルの分位ポートフォリオにおいて、 $k$  を変化させた場合の正解率を図 3 に示す。個別銘柄の結果と比較すると、 $k$  に因らずほぼすべての場合において正解率の向上が見られる。分位を取ることでパフォーマンスが向上したという事実は、予想確率を予測の確度とする妥当性を示唆している。

一方で、 $k = 1$  のときでは個別銘柄の結果とは異なり SVM の正解率が一番低い結果が得られた。本研究では SVM の予測確率は Platt's Scaling [6] より求めているが、正解率を向上させるために予測確率への

キャリブレーション方法を再検討する価値があると言える。

次に、 $k$ を変化させた場合の実現リターンの平均値と標準偏差をそれぞれ図4と図5に示す。個別銘柄のリターンと比較すると、実現リターンの水準については特に大きな差異は見られない。しかしどの予測モデルにおいても、投資対象の分散効果が顕著で  $k = 5$  のとき標準偏差は一番小さくなっている。この投資対象の分散効果はリスク調節後リターンに大きく寄与する。このように予測確率を利用した分位ポートフォリオの構築は個別銘柄投資よりもリターンとリスクの意味で効率的であることがわかる。

以上のように、正解率及び実現リターンにおいて、LSTM が他の機械学習モデルをアウトパフォームする結果が得られた。この結果は S&P500 の実証分析 [3] と整合している。

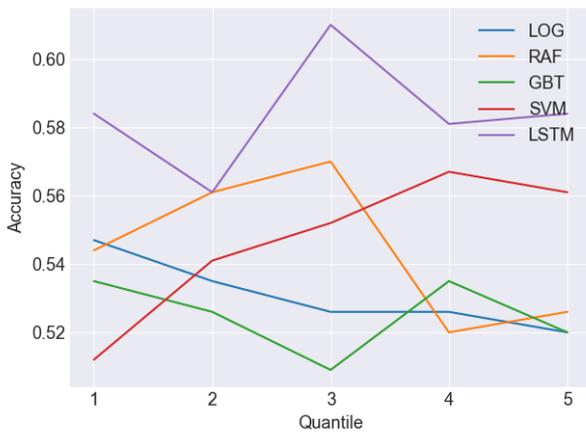


図3 各分位ポートフォリオの正解率の比較

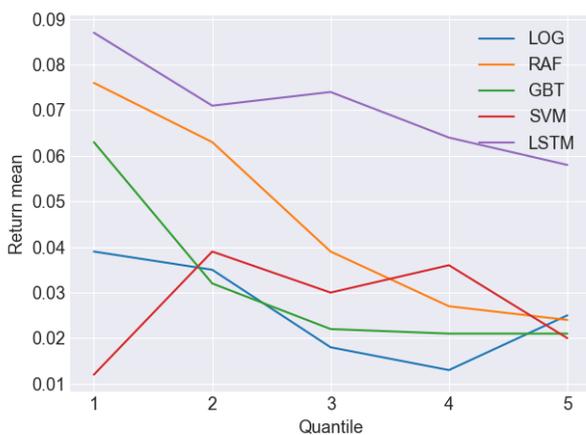


図4 各分位ポートフォリオのリターンの平均

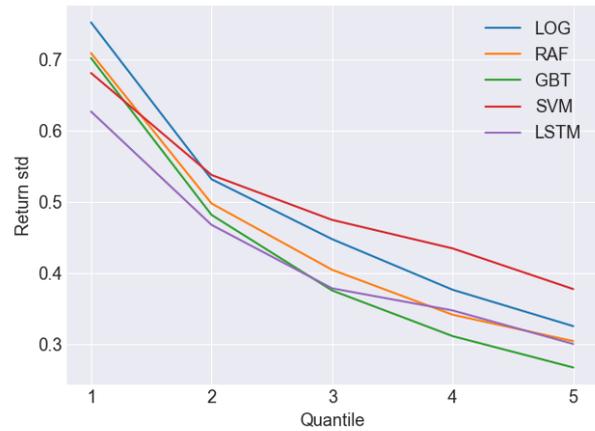


図5 各分位ポートフォリオのリターンの標準偏差

## 6. 結論

TOPIX core30 構成銘柄を対象とした株式リターン予測と投資戦略への応用可能性を議論した。個別銘柄の予測結果では、正解率や実現リターンといった観点で LSTM が最も良いパフォーマンスを示した。またモデルの予測確率を活用した分位ポートフォリオを構築することで、すべてのモデルで正確率向上が見られた。その中でも LSTM は他モデルをアウトパフォームしており、S&P500 構成銘柄を対象とした実証分析結果と整合する結果が得られた。

## 参考文献

- [1] 渡部敏明, ボラティリティ変動モデル, 朝倉書店, 2000.
- [2] A. Ang and G. Bekaert, "International Asset Allocation with Regime Shifts," *The Review of Financial Studies*, vol. 15, no. 4, p. 1137, 2002.
- [3] T. Fischer and C. Krauss, "Deep learning with long short-term memory networks for financial market predictions," *FAU Discussion Papers in Economics*, vol. 11, 2017.
- [4] C. Krauss, X. A. Do and N. Huck, "Deep neural networks, gradient-boosted trees, random forests: Statistical arbitrage on the S&P 500," *European Journal of Operational Research*, vol. 259, no. 2, p. 689, 2017.
- [5] J. Bergstra and B. Kégl, "Algorithms for Hyper-Parameter Optimization," in *NIPS'11 Proceedings of the 24th International Conference on Neural Information Processing Systems*, 2011.
- [6] J. Platt, "Probabilistic Outputs for Support Vector Machines and Comparisons to Regularized Likelihood Methods," MIT press, 1999.

# 日米イールドカーブの連動性を用いた 機械学習に基づく日本国債の長期金利予測

JGB long-term interest rate forecast considering  
the connection between the Japanese and US yield curve

水門善之<sup>1,2\*</sup> 坂地泰紀<sup>1</sup>

和泉潔<sup>1</sup> 島田尚<sup>1</sup> 松島裕康<sup>1</sup>

Yoshiyuki Suimon<sup>1,2</sup> Hiroki Sakaji<sup>1</sup>

Kiyoshi Izumi<sup>1</sup> Takashi Shimada<sup>1</sup> Hiroyasu Matsushima<sup>1</sup>

<sup>1</sup> 東京大学大学院工学系研究科システム創成学専攻

<sup>1</sup> Department of Systems Innovations, School of Engineering  
The University of Tokyo

<sup>2</sup> 野村證券株式会社金融経済研究所経済調査部

<sup>2</sup> Economic Research Department, Financial and Economic Research Center  
Nomura Securities Co., Ltd.,

**Abstract:** 近年、リーマンショックや欧州債務危機に代表される海外発の金融システム不安が、デリバティブ契約等のグローバルな金融取引を通じて、日本の金利市場に大きな影響を与える場面が散見されてきた。この点を踏まえ、本研究では海外市場での金利変動が日本の金利市場に与える影響を検証すると共に、機械学習手法を用いて、海外市場からの影響を考慮した日本市場の金利変動モデルの構築を行った。具体的には、日本国債のイールドカーブの変動を対象として、各種機械学習手法を用いて先行きの予測モデルを構築する際に、米国債のイールドカーブの変動データも学習データとして用いることで、日本の長期金利（長期国債の利回り）の予測精度が向上する傾向を確認した。更に、米国市場のデータを学習に用いた場合に、日本市場の予測精度が向上する度合いが、近年高まっていることも併せて確認した。このことは、海外金利の情報が現在の日本市場の金利予測において有用な情報となることを示唆する結果と見えよう。

## 1. はじめに

長期金利とは、人々の経済活動の活況度合いを映し出す代表的な指標である。一般に長期金利は長期国債（10年利付国債）の利回りを指すことが多い。国債の市場価格は、様々な需給要因の影響を受けつつ、マクロ経済環境の変化を織り込む形で、日々形成されていく。他にも、リーマンショックや欧州債務危機に代表される海外発の金融システム不安、また欧米中央銀行の金融政策変更等を受けた海外市場での金利変動が、日本の金利市場に影響を与える場面も散見される。これらの背景には、デリバティブ契約等のグローバルな金融取引や様々な金利裁定取引を通じて、海外市場における金利変動が、直接的

に日本市場の金利に伝達されるメカニズムが存在していること等が挙げられよう。

本研究では、このように海外市場における金利変動が日本の金利市場に与える影響に着目することで、日本の金利市場の先行きを予測する上での、米国市場データの有用性の検証を行う。始めに、日米の金利データの連動性の検証、及び実際の金融市場参加者を対象としたアンケート結果を用いて、日本の市場参加者が海外データをどの程度考慮して取引を行っているかの検証を行う。その結果を踏まえ、各種機械学習手法（SVM、非線形SVM、決定木、RF、ロジスティック回帰、k近傍法、MLP、RNN、LSTM）を用いた日本市場の金利の変動予測モデルの構築を行う。その際、日本市場の過去の金利の変動データ

\* Email: d2018ysuimon@socsim.org

に加えて、米金利市場の金利の変動データも学習に用いたモデルを提案し、本提案モデルを用いた場合に、日本の長期金利（長期国債の利回り）の予測精度がどの程度向上するかについての検証を行う。更に、前述した昨今の金融システムのグローバル化に伴って、米国市場が日本市場に与える影響が近年上昇していることが想定されることから、この点についても、学習モデルを用いた金利予測のシミュレーションにより、日本市場の予測における米国市場データの有用性が、近年どの程度高まっているかについての検証を行う。

## 2. イールドカーブと長期金利

### 2.1 長期金利と日米金利

長期金利（長期国債の利回り）は、マクロ経済環境を表す代表的指標である。一般に、経済活動が活発な時は、家計の消費や企業の設備投資等が積極的に行われることから、家計や企業が高い金利を支払ってでも資金を調達したいという需要が高まり、結果、銀行貸出や社債、国債等の金利に上昇圧力がかかる。また、国債や社債等の金利は発行体である国や企業のクレジットリスクの影響も受ける。例えば、発行体の財務・財政状況に対する不安が高まると、資金調達コストの上昇という形で、金利に上昇圧力がかかる。他にも、名目ベースの長期金利はインフレの影響も受ける。例えば、人々のインフレ期待が上昇すると名目金利も上昇するという関係は、フィッシャー方程式として知られる。このように、様々なマクロ経済環境の変化を織り込みながら、市場で取引される長期国債の価格は形成され、そこから計算される利回り（長期金利）も日々変化していく。

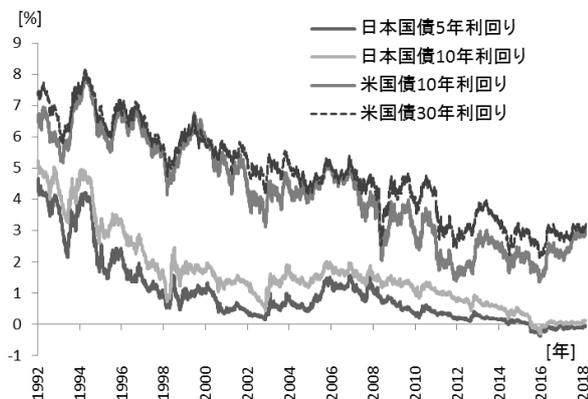


図 1: 日米国債利回りの推移

実際の日本の長期金利（10年国債利回り）の推移を図 1 に示した。また、日本国債の他年限の金利、

並びに、米国債市場の金利データも併せて掲載した。これによると、日米において金利水準の変化はある程度連動しており、また近年は金利水準の低下が生じていることが見て取れる。

### 2.2 国債イールドカーブの期間構造モデル

日米の長期金利の推移は図表 1 に示した通りだが、この他にも様々な年限の金利が存在している。例えば日本では 2 年、5 年、10 年、20 年、30 年、40 年の利付国債が発行されており、幅広い年限の市場金利が存在している。このような異なる年限の金利をつなぎ合わせた曲線はイールドカーブと呼ばれる（図 2）。

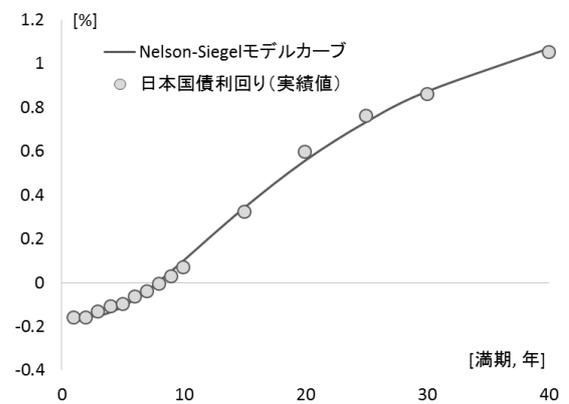


図 2: Nelson-Siegel モデルに基づくイールドカーブ

イールドカーブの形状は、金利の期間構造モデルを用いて表すことができる。例えば、Nelson-Siegel モデル[1]を用いると、以下のような関数形を用いてイールドカーブの期間構造が表現できる。ここでは  $y$  は金利、 $\tau$  は年限、 $\lambda$  は定数とする、

$$y(\tau) = F_1 + F_2 \left( \frac{1 - e^{-\lambda\tau}}{\lambda\tau} \right) + F_3 \left( \frac{1 - e^{-\lambda\tau}}{\lambda\tau} - e^{-\lambda\tau} \right) \quad (1)$$

この関数は、水準、傾き、曲率を表す 3 つのファクター  $F$  の項から成り立っており、それぞれのファクターの年限別の係数を図示すると図 3 のようになる。このような金利の期間構造モデルによって表現される国債金利のイールドカーブだが、基本的にはこれらの金利水準は、マクロ経済環境や金融政策の影響を受けて変動する。ただし、年限によっては国債取引を行う市場参加者の特性や取引目的が異なることから、結果、金利の変動特性も年限によって異なってくる。

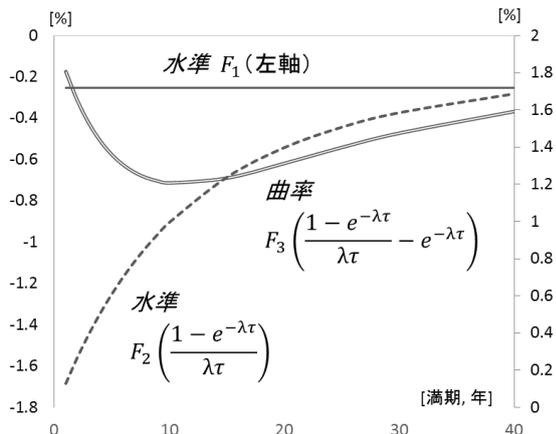


図 3: Nelson-Siegel モデルに基づくイールドカーブ

例えば、日本のマーケットにおいては、短期金利は、一般に中央銀行の金利操作目標の影響を直接的に受けるため変動性は乏しい。一方で、中長期金利は、市場の価格形成メカニズムが働く環境下においては、マクロ経済環境の変化等を織り込みながら柔軟に変動していく。また、年限間の金利差が開きすぎた場合には、高い金利の国債の需要が高まり、結果、金利差に縮小圧力がかかるというメカニズムも存在する。このように、国債イールドカーブは、年限間の相対価値 (Relative Value) や周辺年限の国債との金利差に着目した裁定取引の影響等を受けながら、イールドカーブの形状自身に基づく内生的な要因によって、自身の変動が生み出されていく側面もある。

### 2.3 イールドカーブモデルの構築

本研究では、イールドカーブの期間構造の変動をモデル化するにあたり、水準・傾き・曲率の情報を、5・10・20年の金利変化のデータを用いることで設定したい。図4に示す通り、3つの主要な年限の金利変化の情報を用いることで、各年限の金利水準の変化に加えて、イールドカーブの傾き・曲率の変化の情報も捉えることができる。例えば、5-20年のスプレッド (金利差) はイールドカーブ全体の傾きとして、5-10年スプレッドと10-20年スプレッドの差はイールドカーブ全体の曲率としての意味を持つ。このように3つの年限の金利変化の情報を用いて、金利の期間構造の変化をモデル化することで、前述したイールドカーブの形状という内生的な要因によって生み出される長期金利の変動特性を捉えたモデルの構築を行う。

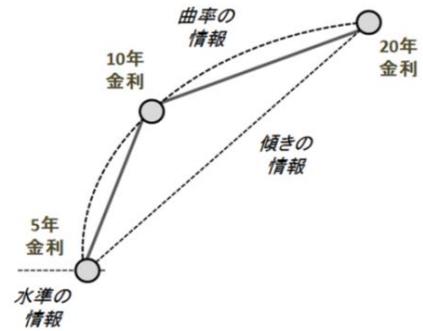


図 4: 金利の期間構造を表す3つのファクター

## 3. 日米イールドカーブの連動性

### 3.1 日本の市場参加者が意識する海外金利

前述の通り、長期金利の変動は他年限の金利との相対関係の影響も受けるが、その他にも海外市場の影響も受けることが想定される。図1で示した通り、日米の金利は、ある程度の連動性が見られる。実際、日本の国債市場の参加者は、海外市場の動きをどの程度気にしているのだろうか。この点を考える上で参考になるのが、QUICK社が毎月、日本の債券市場の参加者を対象に実施しているアンケート調査“QUICK月次調査<債券>”だ。

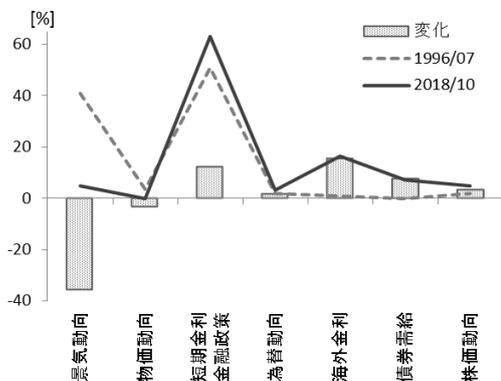


図 5: 債券市場参加者が注目する価格変動要因

本アンケートの中には「最も注目している債券価格変動要因は？」という質問項目があり、図5に示す通り、調査が始まった1996年時点では、債券市場の参加者の中では「金融政策や短期金利」の次に「景気動向」との回答割合が高かった。ただし、2018年時点では「景気動向」に替わって「海外金利」と回答する割合が増えてきている。

図6は、同アンケート調査における「景気動向」と「海外金利」との回答の割合の推移を示したものだ。これによると、2006年頃から「海外金利」の回

答割合が高まってきている傾向が見て取れる。それと同時に「景気動向」の回答割合は低下傾向にあることが分かる。

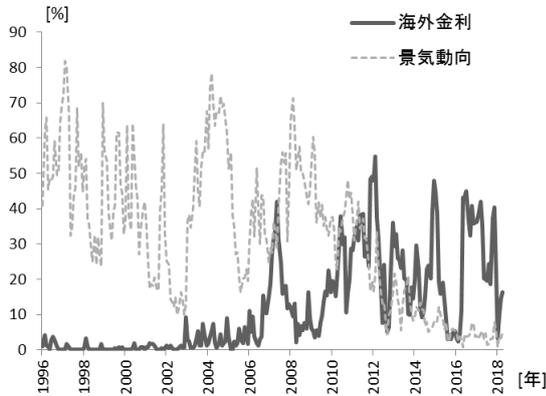


図 6: 債券市場参加者が注目する価格変動要因の推移

実際、2008年のリーマンショックや2010年に発生した欧州債務危機に代表される海外発の金融システム不安、更には欧米中央銀行の金融政策変更やそれに向けた投資家の動きといった、海外金融市場における様々な変動要因が、日本の金利市場の価格形成に大きな影響を与える場面は、近年散見されている。背景には、グローバルな金融機関の間で締結されるデリバティブ契約や、様々な金利裁定取引を通じて、海外金利の変動が直接的に日本の金利に伝達するメカニズムの存在等が想定できよう。そのため、このように、グローバルな金融システムが発達した現代においては、日本の金利とはいえ、日本の景気動向といったファンダメンタルズ要因のみならず、海外市場における金利変動の影響が市場参加者の間で強く意識され、結果として、それが日本国内の金利市場における価格形成に影響を与えている可能性はあるだろう。

### 3.2 日米金利の連動性確認の為の予備実験

本節では、このような市場参加者のアンケート結果を踏まえて、実際に日米のイールドカーブが、互いにどのような影響を与えているかについて、簡単な検証を行った。図7は、日米の日次の金利データを対象として、各年限の米国（日本）の金利が上昇（低下）した翌日に、日本（米国）の市場で同年限の金利が上昇（低下）した割合を示したものだ。これによると、米国の金利が上昇（低下）した翌日には、日本の金利も同方向の動きをする傾向が見られる。一方で、その逆である日本市場から米国市場への金利変動の連動性は限られている。また、前述のアンケート結果を踏まえ、図7では、1992年から2005年の期間及び、2006年から2018年の期間に分けて

検証を行ったが、2006年以降の期間で見た場合、このような非対称性の傾向はより強まっていることが確認できる。特に、10年金利において、日本金利が米国金利の動きに連動する傾向が強い点を踏まえると、日本の長期金利の日次変動予測において、米国市場のデータの有用性が窺えよう。

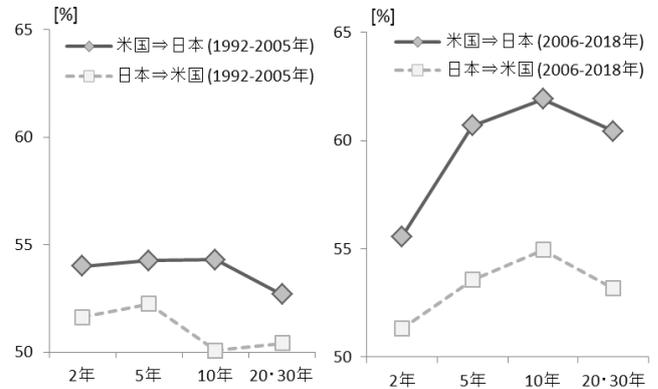


図 7: 日米国債利回りの日次連動性の検証

## 4. 機械学習モデルの構築と金利予測

### 4.1 特徴量エンジニアリング

本章では、これまでの論点を踏まえ、機械学習モデルを用いた日本の長期金利の予測を行う。日本市場の金利データを対象に、機械学習手法に基づく金利の期間構造モデルを用いて、長期金利の予測を行った先行研究としては、[2]が挙げられる。本研究では、先行研究と同じく日本市場の金利データのみを学習に用いたモデルで日本の長期金利を予測した場合と、それに加えて、米国市場の金利データも学習に用いたモデルで日本の長期金利を予測した場合とで、予測精度がどの程度改善するかについて検証を行う。

まず、2.3節で言及した通り、日本国債（JGB）の5,10,20年の金利変化のデータを用いて金利の期間構造のモデル化を行う。具体的には、各年限（5,10,20年）の過去3日間の日次の金利変化をインプットデータとし、更に、各年限の翌日にかけての金利変化をラベルデータとして、機械学習に基づく金利の期間構造の変動モデルを構築する。学習に用いるインプットデータとラベルデータの関係は図8に示した通りである。本モデルにより、5,10,20年の3つの年限の3日分の金利変化のデータを基に、各年限の翌日にかけての金利変化が予測可能となる。

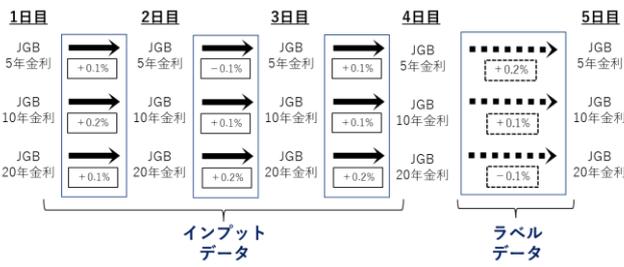


図 8: インプットデータとラベルデータの設定  
(日本市場データ対象時)

次に、日本市場の金利データに加えて、米国市場の金利データも学習に用いたモデルを構築する。具体的には、過去3日間の日本国債（JGB）の5,10,20年の金利変化に加えて、過去3日間の米国債（UST）の5,10,30年の金利変化もインプットデータとし、その翌日にかけての日本国債の5,10,20年の金利変化をラベルデータとして、モデルの学習を行う。学習に用いるこれらインプットデータとラベルデータの関係は図9に示した通りである。

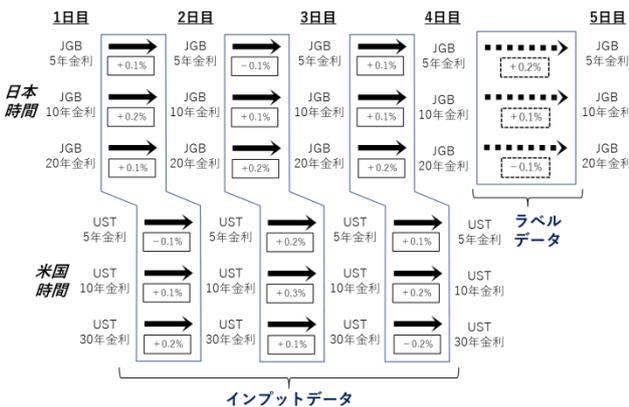


図 9: インプットデータとラベルデータの設定  
(日米市場データ対象時)

ポイントとなるのが、日本時間と米国時間の違いだろう。米国市場の終値のデータが得られるのは、同日の日本市場が閉じた半日程度後である。また、日本時間の5日目の市場が開く前に4日目の米国時間の取引が終了するため、両市場の取引時間は重複しない。この点を踏まえ、日本の5,10,20年金利に加えて、米国の5,10,30年金利のデータをインプットデータとして用いることで、翌日にかけての日本の金利変化の予測精度向上を目指す。

## 4.2 金利の変動モデルの構築

本研究では、1992年8月から2018年9月までの日本及び米国の国債利回りの日次変化のデータを対象として、代表的な機械学習手法である、SVM（サ

ポートベクターマシン）、DT（決定木）、RF（ランダムフォレスト）、ロジスティック回帰、k近傍法、更にはMLP（多層パーセプトロン）、RNN（リカレントニューラルネットワーク）、LSTM（ロングショートタームメモリ）に基づく、モデルの実装を行う[3][4]。なお、日本国債の利回りは財務省より、米国債の利回りは米連邦準備銀行より公表されている。モデルの学習の際には、SVM、決定木、RF、ロジスティック回帰、k近傍法においては、過去3日間の金利変化の情報（3日分の日本国債の5年、10年、20年の金利変化、また比較対象としては、これらに加えて米国債の5年、10年、30年の金利変化）をインプットデータとし、翌日の日本国債の10年金利の変化が上昇か低下かの二値を教師ラベルとして、学習を行う。

また、MLPの場合は、過去3日間の金利変化の情報（3日分の日本国債の5年、10年、20年の金利変化、また比較対象としては、これらに加えて米国債の5年、10年、30年の金利変化）をインプットデータとし、翌日の日本国債の5年、10年、30年の金利変化の情報を教師ラベルとして学習を行う。ネットワークの模式図は図10に掲載した通りである。米国のデータを用いる場合、インプットデータのベクトルが6次元（=3つの年限の金利変化×2カ国）となる一方、アウトプットのベクトルは日本の5年、10年、20年の金利変化に対応した3次元となる。

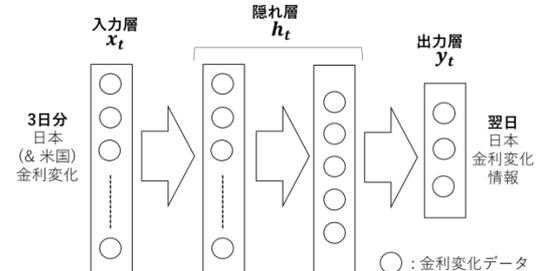


図 10: MLPにおけるニューラルネットワークの構造

更に、RNN、LSTMに基づく学習モデルの場合は  $t-1$  日から  $t$  日にかけての日本国債の5年、10年、20年の金利変化という3次元のベクトルを入力データ  $x_t$  として設定する（比較対象として、米国の情報も用いる場合は、これらに加えて米国金利の5年、10年、30年の金利変化も入力データとして使用する）。

$$x_t = \begin{pmatrix} r_t^{JP20} - r_{t-1}^{JP20} \\ r_t^{JP10} - r_{t-1}^{JP10} \\ r_t^{JP5} - r_{t-1}^{JP5} \\ r_t^{US30} - r_{t-1}^{US30} \\ r_t^{US10} - r_{t-1}^{US10} \\ r_t^{US5} - r_{t-1}^{US5} \end{pmatrix}, y_t = \begin{pmatrix} r_{t+1}^{JP20} - r_t^{JP20} \\ r_{t+1}^{JP10} - r_t^{JP10} \\ r_{t+1}^{JP5} - r_t^{JP5} \end{pmatrix}$$

そして、これらの過去3日間の変化  $x_t, x_{t-1}, x_{t-2}$  をリカ

レントなネットワークにおけるインプットデータ、更に  $t$  日から  $t+1$  日にかけての 5 年、10 年、20 年の金利変化のベクトル  $y_t$  を教師ラベルとして、モデルの学習を行う。

表 1: 各機械学習モデルの構造リスト

表記	モデル	モデル構造
Same	前日と同じ方向	JP: 前日の日本市場の動きと同方向 JP&US: 昨日の米国市場の動きと同方向
LinRe	線形回帰(重回帰)	
LogiRe	ロジスティック回帰	正則化パラメータ C=1
LinSVM	サポートベクターマシン(線形)	ペナルティパラメータ C=1
SVM	サポートベクターマシン(非線形)	ガウシアンカーネル使用 ペナルティパラメータ C=1
DT	決定木	
RF	ランダムフォレスト	
kNei	k近傍法	k=5
MLP1	多層パーセプトロン	活性化関数: ハイバボリックタンジェント 各レイヤーのノード数 JP: 9-5-3, JP&US: 18-10-3
MLP2	多層パーセプトロン	活性化関数: ハイバボリックタンジェント 各レイヤーのノード数 JP: 9-9-5-3, JP&US: 18-18-10-3
RNN1	リカレントニューラルネットワーク	活性化関数: ハイバボリックタンジェント 隠れ層のノード数: 100
RNN2	リカレントニューラルネットワーク	活性化関数: ハイバボリックタンジェント 隠れ層のノード数: 50
LSTM1	ロングショートタームメモリ	活性化関数: ハイバボリックタンジェント リカレント活性化関数: シグモイド LSTMブロックの数: 100
LSTM2	ロングショートタームメモリ	活性化関数: ハイバボリックタンジェント リカレント活性化関数: シグモイド LSTMブロックの数: 50

## 5. 予測モデルの評価と検証

### 5.1 学習モデルの長期金利予測精度の検証

本章では、前述した各種学習モデルに基づく日本の長期金利（10 年国債利回り）予測の検証結果を示す。ここでは、QUICK 社のアンケート結果、及び III-B 章で行った予備実験の結果を踏まえ、サンプル期間を 1992 年から 2005 年までの期間と、2006 年から 2018 年までの期間に分けて検証を行った。検証方法としては、各サンプル期間のデータに対し、ランダムに抽出した 8 割を訓練データとしてモデルの学習を行い、残り 2 割をテストデータとして学習済みモデルの予測精度を検証した。

具体的には、SVM、決定木、RF、ロジスティック回帰、k 近傍法に基づく予測モデルの検証においては、テストデータに対して、学習済みモデルを用いて直接予測を行った翌日の 10 年金利の方向性を、実際の方向性と比較することで予測精度の検証を行っ

た。MLP、RNN、LSTM に基づく予測モデルの検証では、テストデータに対して、学習済みモデルを用いて予測した翌日の 10 年金利の変動幅に基づく方向性と、実際の方向性との比較を行った。また、本検証においては、米国市場のデータを学習に使用した場合と、使用しなかった場合との比較の為に、学習に用いたデータの期間及び、検証に使用したテストデータの期間は、両分析において共通の期間としている。各機械学習モデルの構造については表 1 を参照されたい。

### 5.2 考察

各種モデルに基づく、日本の長期金利の翌日の上昇・低下の方向性予測の正答率を図 12 に掲載した。ここでは、モデルの学習の際に日本市場の金利データのみを用いた場合（米国データ未使用）と、米国市場の金利情報も学習に用いた場合（米国データ使用）とに分けて、長期金利の予測精度を示した。更に図 11 では、二つの図表を用いて、2006 年以前と以降の期間を対象に、各 2 種類のテストデータを用いた正答率を示したが、これによると、米国市場の金利データを学習に用いた場合、2006 年以降の期間において、日本の長期金利の予測精度に大幅な改善が確認できる。

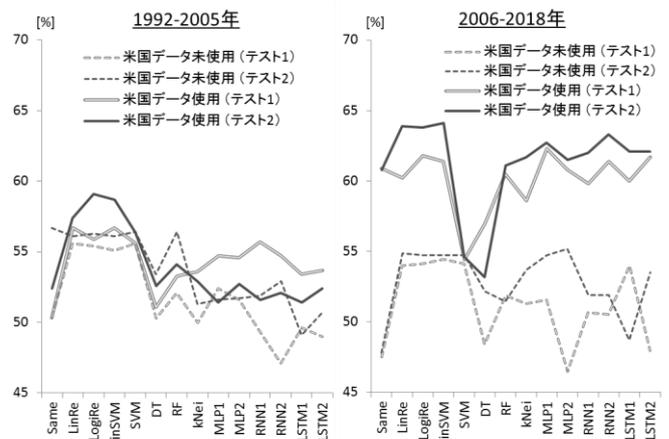


図 11: 各モデルに基づく日本の長期金利予測の正答率

2006 年以降の期間では、いずれの学習アルゴリズムを用いた場合でも、米国市場の金利データを学習に用いることによる予測精度の改善が顕著であり、特に、ロジスティック回帰や SVM、また各種ニューラルネットワークに基づくモデルを用いた場合、同程度に良好な予測パフォーマンスが確認できた。このことは、前述のアンケート結果や予備実験が示唆したように、近年、米国金利の情報が、翌日の日本の長期金利の動向を予測する上で、有用な情報となることを示す結果と言えよう。

## 6. 関連研究

本研究では、日米の国債市場における金利の期間構造の変動を機械学習手法を用いてモデル化し、それに基づいて日本の長期金利の変動予測を行った。本研究に関連する先行研究としては、本研究でも着目した Nelson-Siegel モデル[1] を用いて米国債市場のイールドカーブをモデル化し、更に Nelson-Siegel モデルの3つのファクターの変化を時系列分析手法の一種である AR(1)モデルを用いて予測した[5]が挙げられる。

イールドカーブに対するファクター分析としては、主成分分析を用いて3つの主成分ファクターを抽出し、各ファクターの時系列をモデル化することで、イールドカーブ変化の予測を行った[6]も挙げられる。また、主成分分析を用いたアプローチとして、[7]や[8]は、様々なマクロ指標を対象として主成分分析を行い、それによって作成したマクロベースの主成分ファクターを金利の予測に活用するといった研究も行っている。

更に、深層学習等の機械学習手法をイールドカーブ変動の予測に用いた研究としては、[2]が挙げられる。[2]は、Nelson-Siegel モデルの3つのファクターの代わりに、イールドカーブの3点（5年、10年、20年）の金利の相対関係に着目することで、金利の期間構造を表現し、かつそれらの変動を LSTM を含む機械学習手法を用いてモデル化することで、長期金利の予測を行った点が特徴的である。

## 7. 結論

本研究では、米国市場の金利変動が、日本市場に与える影響に着目することで、各種機械学習手法を用いた日本市場の金利変動予測における、米国市場の情報の有用性の検証を行った。具体的には、先行研究[2]の手法にならう形で日本市場の金利データのみを学習に用いて日本の長期金利を予測した場合と、それに加えて、米国市場の金利データも学習に用いて日本の長期金利を予測した場合とで、どの程度予測精度が改善するかについて検証を行った。その結果、日本市場の金利データに加えて、米国市場の金利データも学習に用いることで、特に近年においては、日本の長期金利予測の精度が大きく向上する傾向が確認できた。このことは、日本国債の市場参加者を対象に行ったアンケート調査において、2006年頃以降、海外金利を注視する傾向が強まりをみせている点と整合的であろう。近年の金融市場においては、海外発の金融危機や、海外中銀の金融政策変更といった、海外における様々な金利の変動要

因が、グローバルな金融機関同士のデリバティブ契約や、様々な金利裁定取引を介して、直接的に日本市場の金利に影響を与え得るパスが存在している。本研究の結果は、このような、グローバルな金融システムが発達した現代において、海外金利の動向が、国内金利の予測において有用な情報となることを示唆する結果と言えよう。

## 参考文献

- [1] Charles Nelson and Andrew F Siegel, “Parsimonious Modeling of Yield Curves,” *The Journal of Business*, Vol.60, No.4, pp.473-489, 1987
- [2] 水門善之, “機械学習を用いた国債イールドカーブの変動モデルの構築と長期金利予測,” 人工知能学会金融情報学研究会, No.21, pp.46-49, 2018
- [3] Sepp Hochreiter and Jürgen Schmidhuber, “Long Short-Term Memory, *Neural Computation*,” Vol.9, No.8, pp.1735-1780, 1997
- [4] Felix A. Gers, Jürgen Schmidhuber and Fred A. Cummins, “Learning to Forget: Continual Prediction with LSTM,” *Neural Computation*, Vol.12, No.10, pp.2451-2471, 2000
- [5] Francis X. Diebold and Canlin Li, “Forecasting the term structure of government bond yields,” *Journal of Econometrics*, Vol.130, pp.337-364, 2006
- [6] Haim Reisman and Gady Zohar, “Short-Term Predictability of the Term Structure,” *The Journal of Fixed Income*, Vol.14, No.3, pp7-14, 2004
- [7] Emanuel Moench, “Forecasting the yield curve in a data-rich environment: A no-arbitrage factor-augmented VAR approach,” *Journal of Econometrics*, Vol.146, No.1, pp26-43, 2008
- [8] Sydney C. Ludvigson and Serena Ng Author, “Macro Factors in Bond Risk Premia,” *The Review of Financial Studies*, Vol.22, No.12, pp.5027-5067, 2009

## 留意事項

本稿は、著者の個人見解を表すものであり、野村證券株式会社の公式見解を表すものではありません。

# テクニカル指標による金融取引の戦略木構築

## Construction of a Strategy Tree in Financial Transaction using Technical Indicators

加藤 旺樹<sup>1</sup> 穴田 一<sup>1</sup>

Ohki Kato<sup>1</sup> Hajime Anada<sup>1</sup>

<sup>1</sup> 東京都市大学大学院 総合理工学研究科

<sup>1</sup> Graduate School of Integrative Science and Engineering, Tokyo City University

**Abstract:** In recent years, many researchers have studied stock trading using technical analysis. However, it is necessary to have deep knowledge to use such technical analysis and it is difficult to make a profit using such techniques. Therefore, we construct an evolutionary model to create a profitable investment strategy using technical indicators.

### 1. はじめに

近年、テクニカル分析を用いた株式売買に関する研究が精力的に行われている。テクニカル分析を用いた投資では、相場のトレンドや転換点を判断するテクニカル指標を用いることで、過去の値動きのパターンから将来の値動きを予測し、売買を行う。しかし、そのためには専門的な知識を必要とする上、利益を上げにくいという問題がある。

松村らは、テクニカル指標を用いた投資戦略を木構造で戦略木として表現した。そして、それぞれの個体が戦略木を持ち、その戦略木に従い株式売買を行うモデルを構築した[1][2]。戦略木を個体の遺伝子として遺伝的操作を用いることで、より利益が高くなるように個体を進化させ、各個体が持つ戦略木の特徴を分析した。ところが、その戦略木は上昇トレンドのみでしか稼ぐことが出来ないものとなっていた。

そこで本研究では、松村らの研究で用いられた戦略木を用いて、テクニカル指標を用いたより利益を生み出す投資戦略の構築を目的とする。

### 2. 提案手法

それぞれの個体が戦略木を持ち、その戦略木にしたがって取引を行う。その取引結果から個体を評価した値である適応度を求め、戦略木を構成するノードを個体の遺伝子として遺伝的操作を用いることでより適応度が高くなるように個体を進化させていく。

#### 2.1. テクニカル指標

テクニカル指標は株式の売買タイミングを判断するために使われる指標で、トレンド系、オシレータ

系、出来高系の3つがある。トレンド系は株価の推移からトレンドを判断する指標、オシレータ系は株価の推移からトレンドの転換点を判断する指標、出来高系は売買が成立した株数の推移からトレンドの転換点を判断する指標である。

#### 2.2. 戦略木

戦略木は、複数の非終端ノードと終端ノードからツリー状に構成される。図1に戦略木の例を示す。それぞれの数字がテクニカル指標や売買行動を表し、各ノードから1番上のノードまでのノード間を結ぶ枝の数を各ノードの深さとする。

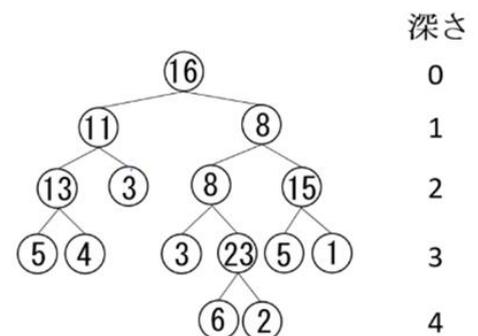


図1 戦略木の例

各個体は戦略木を持ち、戦略木に従って当日の行動を決定する。一番上のノードからテクニカル指標に基づく判定処理により、左右どちらのノードを実行するのか決定していくことを繰り返し、到達した終端ノードの行動を実行する。判定に使用するデータは、各指標に必要な日数分の始値、高値、安値、終値、出来高の日足データである。

非終端ノードでは、テクニカル指標に基づく判定処理によって左右どちらかのノードを実行する。終端ノードでは、株式の売買行動を実行する。使用する

表 1 終端ノードと非終端ノード

種類	番号	内容
終端ノード	1	1株購入, 資金がないときは待機
	2	1株売却, 株式がないときは待機
	3	待機
	4	所有している株式をすべて売却
	5	資金が許す限り株式を購入
	6	初期資産の10%を使い株式を購入
	7	所有株式の10%を売却
非終端ノード	8	前日の終値が前々日の終値より高ければ左のノードを実行, それ以外であれば右のノードを実行
	9	前日の出来高が前々日の出来高より高ければ左のノードを実行, それ以外であれば右のノードを実行
	10	前々日 STC·slow < STC·fast, 前日 STC·slow > STC·fast ならば左のノードを実行, それ以外であれば右のノードを実行
	11	前々日 STC·slow > STC·fast, 前日 STC·slow < STC·fast ならば左のノードを実行, それ以外であれば右のノードを実行
	12	%Rを用いて0が連続して3回出た後に前日の値が20以上ならば左のノードを実行, それ以外であれば右のノードを実行
	13	%Rを用いて100が連続して3回出た後に前日の値が80以上ならば左のノードを実行, それ以外であれば右のノードを実行
	14	RSI > 70%ならば左のノードを実行, それ以外であれば右のノードを実行
	15	RSI < 30%ならば左のノードを実行, それ以外であれば右のノードを実行
	16	短期移動平均と前日の終値の間に+10%以上の乖離があれば左のノードを実行, それ以外であれば右のノードを実行
	17	短期移動平均と前日の終値の間に-10%以上の乖離があれば左のノードを実行, それ以外であれば右のノードを実行
	18	長期移動平均と前日の終値の間に+10%以上の乖離があれば左のノードを実行, それ以外であれば右のノードを実行
	19	長期移動平均と前日の終値の間に-10%以上の乖離があれば左のノードを実行, それ以外であれば右のノードを実行
	20	ゴールデンクロスであれば左のノードを実行, それ以外であれば右のノードを実行
	21	デッドクロスであれば左のノードを実行, それ以外であれば右のノードを実行
	22	短期移動平均との間に+2σ以上の乖離があれば左のノードを実行, それ以外であれば右のノードを実行
	23	短期移動平均との間に-2σ以上の乖離があれば左のノードを実行, それ以外であれば右のノードを実行
	24	長期移動平均との間に+2σ以上の乖離があれば左のノードを実行, それ以外であれば右のノードを実行
	25	長期移動平均との間に-2σ以上の乖離があれば左のノードを実行, それ以外であれば右のノードを実行
	26	VR1 ≤ 70%ならば左のノードを実行, それ以外であれば右のノードを実行
	27	VR1 ≥ 45%ならば左のノードを実行, それ以外であれば右のノードを実行
	28	VR2 ≤ 30%ならば左のノードを実行, それ以外であれば右のノードを実行
	29	VR2 ≥ 70%ならば左のノードを実行, それ以外であれば右のノードを実行
	30	WVR ≤ 40%ならば左のノードを実行, それ以外であれば右のノードを実行
	31	WVR ≥ 40%ならば左のノードを実行, それ以外であれば右のノードを実行

るノードは松村らの研究に用いられたノードに加え、ある程度まとめて株式を売買することが出来るようにするため終端ノードに「初期資産の10%を使い株式を購入」という6番のノードと「所有株式の10%を売却」という7番のノードを追加する。表1に終端ノードと非終端ノードを示す。

使用しているテクニカル指標を以下に示す。

- STC-slow, STC-fast (ストキャスティクス値)  
一定期間の株価の最高値と最安値から株価の転換点を判断するオシレータ系の指標
- RSI  
一定期間の株価の値上がり幅と値下がり幅から株価の転換点を判断するオシレータ系の指標
- %R  
一定期間の株価の最高値と最安値から株価の転換点を判断するオシレータ系の指標
- VR1, VR2, WVR (ボリュームレシオ)  
出来高の推移から株価の転換点を判断する出来高系の指標

### 2.3. 遺伝子操作

戦略木を構成するノードを個体の遺伝子として、

交叉や突然変異、淘汰の操作でより高い利益を生み出す個体を作り出していく。

#### 2.3.1. 初期個体生成

表1のノードの中から無作為に1つを選択する。そのノードが終端ノードであれば、戦略木の生成を終了する。非終端ノードであれば、その非終端ノードの左右にノードを無作為に選択して付け加える。この作業を、全ての非終端ノードの左右に終端ノードが付け加えられるまで繰り返す。初期個体の生成は、初めからノード数の多い木になることを防ぐため、深さ4には終端ノードを付け加える。初期個体はN個体生成する。

#### 2.3.2. 評価

個体の適応度は利益の幾何平均とする。複数の期間でそれぞれ取引を行った時の利益の幾何平均を適応度とすることで、どの期間でも利益を上げている個体の適応度が高くなるようにする。さらに、学習データを銘柄ごとに短く分割することでトレンド等の時系列の特徴を出やすくした状態で学習を行う。期間をより細かく分割し、分割したそれぞれの期間で取引させた時の利益の幾何平均を適応度とするこ

とで、多くの変動パターンを学習出来ると考えたからである。しかし、利益は負になることがあり、その場合適応度を求めることができない。そこで、利益が負の場合、取引の中で最も小さい利益の絶対値を全ての利益に足すことで補正する。

### 2.3.3. ノード削除

戦略木によって行動を決定する際に同じ数字のノードを2回目以降実行する場合、そのノードでは左右どちらのノードを実行するのか決まっているため、絶対に到達できないノードが生まれてしまう。例えば、図1では、深さ1と深さ2に8番のノードがある。深さ1にある8番で左のノードを実行する場合、深さ2の8番も左のノードを実行することになり、その逆側の深さ3の23番のノード以下には到達できない。これらのノードは売買行動に関係なく適応度に影響を与えないが、ノード数を制限していないためこのようなノードが際限なく増えていく。これでは交叉時、適応度に影響を与える部分が選ばれにくくなり、進化が停滞しやすく効率的な学習が妨げられる。そこで、戦略木がある程度大きくなってから必要ない部分を削除するために、101世代以降では毎世代評価で使われなかったノードの削除を行う。ノードの削除を101世代以降で行うのは、初期世代から行くと戦略木が大きくなってしまふからである。

### 2.3.4. 交叉

現代の全個体から適応度を用いたルーレット選択により親となる2個体を選択する。それぞれの個体から無作為に1つずつノードを選び、そのノード以下の部分木を交換することで子を2個体作り出す。これらの操作を繰り返すことでN個体を作り出す。

### 2.3.5. 突然変異

現代のN個体と交叉によって出来たN個体について適応度の順位に基づいて突然変異を施すか決定する。個体*i*の突然変異が起きる確率 $P_i$ は次式で定義される。

$$P_i = (\text{Rank}_i - 1) \times 0.1 \quad (\%) \quad (1)$$

ここで、 $\text{Rank}_i$ は個体*i*の適応度の順位である。これにより、順位の高い個体は突然変異する確率が低くなる。突然変異を施す場合、個体を構成する各ノードが突然変異率*p*(%)で、終端ノードなら他の終端ノード、非終端ノードなら他の非終端ノードに無作為に変化させる。これらの個体を次世代に残す。

### 2.3.6. 次世代に残す個体の選択

次世代に残す個体を全2N個体から適応度の順位

を用いたルーレット選択によって選び出す。こうすることで、個体の多様性を保ちつつ順位の高い個体を次世代に残りやすくする。

## 2.4. 提案手法の流れ

個体をN個体用意する。個体はそれぞれ戦略木と現金残高、保有株式数の情報を持ち、1日1回売買行動する。各個体は独立して、戦略木に従い定めた期間、複数銘柄でそれぞれ取引を行う。取引は過去のデータを用いて実市場と同じ値動きを再現した市場で行い、株式の注文は注文を出した日の終値で成立させる。提案手法は以下の流れで行う。

- I) 初期個体生成
  - II) 初期個体の評価
  - III) 交叉
  - IV) 交叉によって出来た個体の評価
  - V) 交叉によって出来た個体の使われないノード削除
  - VI) 突然変異
  - VII) 突然変異した個体の評価
  - VIII) 突然変異した個体の使われないノード削除
  - IX) 次世代に残す個体の選択
- I), II)の後 III)~IX)を、決められた世代数まで繰り返す。

## 3. 結果

本研究で扱う取引銘柄は、東京証券取引所1部に上場している10業種から、様々な変動を学習させるために、出来高が多く長い期間データを取ることが出来る銘柄を1つずつ選び出した、表2の10銘柄である。

表2 取引銘柄

業種	銘柄
製造業	キヤノン
水産・農林業	極洋
鉱業	日鉄鉱業
建設業	積水ハウス
金融保険業	野村ホールディングス
不動産業	三井不動産
運輸・情報通信業	KDDI
電気・ガス業	大阪ガス
サービス業	セコム
商業	イオン

個体数N=100, 世代数5000, 試行回数50,  $p=0.5$ (%)とし、学習期間は2000年から2005年とした。学習期間の分割の刻みは、2年, 1年, 6ヶ月の3つである。分割した期間においてそれぞれ元金10万円とし、全銘柄で取引を行う。例えば、2年刻みであれば、1銘柄につき6年間の学習期間を2000年1月~

2001年12月, 2002年1月~2003年12月, 2004年1月~2005年12月の3期間に分け, 10銘柄分で30パターンの株価変動で取引し適応度を計算する. テスト期間は2006年から2016年とし1年ごとにテストを行った.

図2にその世代で適応度が最も高い個体の1年間に換算した学習期間での平均利益を示す. 学習期間には様々な変動が存在するが, 上昇トレンドが多い期間となっている. この図は, 50試行を平均したものであり, 縦軸は平均利益(万円), 横軸は世代数を表し, 黒線は既存手法の平均利益, オレンジ線は2年刻みによる提案手法の平均利益, 青線は1年刻みによる提案手法の平均利益, 緑線は6ヶ月刻みによる提案手法の平均利益を表す.

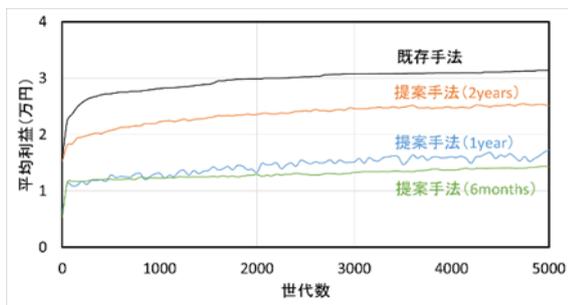


図2 最良個体の平均利益の世代推移 (学習期間)

学習期間において既存手法が最も利益を上げることが出来ている. これは既存手法では稼ぎやすい上昇トレンドのみで利益を上げるように進化しており, 提案手法では様々なパターンの変動で利益を上げようと進化しているため上昇しているところで十分に稼ぐことが出来ていないためである. 短く分割し学習を行ったものほど利益を上げることが出来ないのは, より多くのパターンで利益を上げようと進化しており, 上昇トレンドで稼ぐことがより難しくなっているためである.

図3に2009年においてテストを行った結果を示す. 2009年は下降トレンド後, 上昇トレンドまたは横ばいの銘柄が多い期間である. 図3は, その世代で適応度が最も高い個体の1銘柄あたりの1年間に換算した平均利益の世代推移を表しており, 50試行の平均した結果である. 縦軸は平均利益(万円), 横軸は世代数を表し, 黒線は既存手法, オレンジ線は2年刻みによる提案手法, 青線は1年刻みによる提案手法, 緑線は6ヶ月刻みによる提案手法の平均利益を表す.

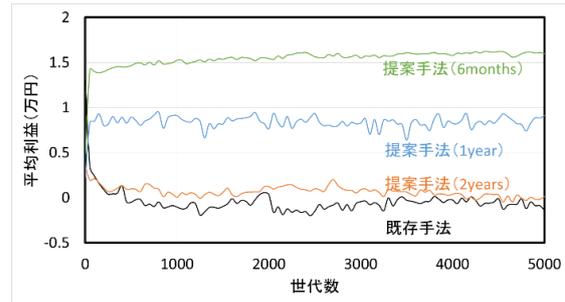


図3 最良個体の平均利益の世代推移 (2009年)

最終世代ではどの刻みによる提案手法も既存手法の利益を上回っており, 短く分割し学習を行ったものほど利益を上げることが出来ている. 既存手法は学習期間では最も利益を上げることが出来ていたが, このテスト期間では利益を上げることが出来ていない. 1年刻みと6ヶ月刻みによる提案手法は学習期間では既存手法より利益を上げることが出来ていなかったが, このテスト期間では利益を上げることが出来ている. これは, 既存手法は上昇トレンドのみでしか稼ぐことが出来ないように進化したため, テスト期間の変動に対応できず, 1年刻みと6ヶ月刻みによる提案手法は, 様々なパターンの変動で利益を上げようと進化しているため, テスト期間の変動にも対応することが出来たからだと考えられる.

他の期間でもテストを行ったところ, 提案手法は上昇トレンドでは既存手法に劣るが, 他の変動では上回ることが出来た. 発表時には, 為替において実験した結果についても触れる.

## 4. 今後の課題

より多くの変動パターンを学習させるため, さらに細かく区切ることも考えている. また本研究では, 学習期間を区切る際に1月を初めとしているが, 季節や年度によって区切ることも考えている. 季節を考慮した区切り方であれば, 春を3月~5月, 夏を6月~8月, 秋を9月~11月, 冬を12月~2月として区切り学習を行う. 年度を考慮した区切り方であれば, 4月を初めとして学習期間を区切り学習を行う.

## 参考文献

- [1] 松村幸輝, 国屋美敬, 木村周平: 遺伝的プログラミング手法に基づくエージェントベーストレーダモデル, 情報処理学会論文誌, Vol.47, No9, pp.2869-2886, (2006)
- [2] 松村幸輝: 進化計算手法にクラスタリングを応用した株式投資の戦略木最適化モデル, 情報処理学会論文誌, Vol.49, No1, pp.457-475, (2008)

# 財務指標とマクロ経済インデックスに基づく 中小企業のデフォルト予測

## Default Prediction for Small and Medium-sized Companies with Financial Indicators and Macroeconomic Indexes

大石 敬昌<sup>1\*</sup>  
Takamasa Oishi

田中 利幸<sup>1†</sup>  
Toshiyuki Tanaka

京都大学大学院情報学研究科<sup>1</sup>  
Graduate School of Informatics, Kyoto University

**Abstract:** The goal of our research is to build default prediction models on the basis of machine learning models and to obtain useful information for corporate credit risk evaluation. The novelty of this work is twofold. The first point is on how to use time-series information of macroeconomic indexes for the default prediction model for small and medium-sized companies. Since macroeconomic indexes and financial data are different in frequency of being obtained, we considered how to combine these two kinds of data, as input of the default prediction model. In order to combine these data, we summarized time-series information of macroeconomic indexes in the form of mean, percentage change, and volatility. Regarding percentage change, some periods were adopted for the purpose of summarizing both of macro trends and micro trends. The summarized forms and corporate financial indicators were used as input of the default prediction model in this research. As a result, the default prediction model with inputs of the financial indicators and the macroeconomic indexes outperformed the model with inputs of only financial indicators. Furthermore, the model, to the inputs of which the percentage changes in the fine periods summarizing micro trends were added, outperformed the model not considering the percentage changes in the fine periods. Therefore, considering macroeconomic indexes, especially our proposed method summarizing macro trends and micro trends, has been found effective for default prediction. The second point is regarding which financial indicators are important in default prediction for small and medium-sized companies by industry sectors. We divided companies into eight industry sectors and investigated which financial indicators are important in each industry sector on the basis of variable importance evaluated with random forest.

## 1 Introduction

Tightness of banks with their money for small and medium-sized private companies is at issue recent years. One of the reasons for the tightness is “International convergence of capital measurement and capital standards”, which was established by Basel Committee on Banking Supervision in 1988. Since 1988, the development of financial derivative products and the collapse of the bubble economy have enhanced the necessity for tightening the regulation concerning risk taking of the banks. That is why the Basel Capital Accord has been strengthened from Basel I to Basel II and Basel III, in 2004 and in 2010, respectively. Tightening the regulation for risk taking of the banks has forced the banks to avoid their risks. The necessity that the financial institutions assess credit risk of companies precisely has developed credit risk evaluation models by using machine learning.

Availability of a sufficient amount of training data is a key to success of machine learning models. Since it is mandatory for listed companies to publish their financial reports periodically, a sufficient amount of data are available to make high-performing credit risk evaluation models for listed companies to learn well. On the other hand,

unlisted companies, typically small or medium-sized, do not have to publish their financial reports, making it difficult for us to collect an enough amount of data for training machine learning models for credit risk evaluation of small and medium-sized companies. Consequently, the banks had tightness with their money for small and medium-sized companies. In order to facilitate finance for small and medium-sized companies smoothly, it is urgent to collect and analyze financial data of small and medium-sized companies. In Japan, the Credit Risk Database institution (CRD) has been collecting and analyzing financial data of small and medium-sized companies, with the vision of realizing smoothing finance for small and medium-sized companies and advancing management of credit risk. Since the database of CRD contains financial data of over one million small and medium-sized companies, it is ideal for use as training data for machine learning models for credit risk evaluation of small and medium-sized companies. The goals of our research are to build default prediction models for small and medium-sized companies on the basis of machine learning models and to obtain useful information for corporate credit risk evaluation for small and medium-sized companies. To achieve the goals, we use the financial data of small and medium-sized companies provided by CRD.

The novelty of this work is twofold. The first point is on how to use time-series information of macroeconomic indexes in a default prediction model. Not only corporate financial data but also macroeconomic factors should

\*京都大学大学院情報学研究科  
〒606-8501 京都府京都市左京区吉田本町  
E-mail: oishi@sys.i.kyoto-u.ac.jp

†Email: tt@i.kyoto-u.ac.jp

be considered for default prediction. For example, difficulty of obtaining loans differs from high-interest period to low-interest period. Existence of strong correlation between corporate credit risks and macroeconomic indexes has been reported [Bonfim 09, Ali 10, Chen 14, 大橋 03, 尾木 13]. Therefore, default prediction model may be more accurate by considering macroeconomic factors than not. However, there is one serious problem in using macroeconomic indexes for default prediction model. The problem is difficulty of combining macroeconomic indexes and financial data because macroeconomic indexes and financial data are different in frequency of being obtained. Financial data of small and medium-sized companies are typically available once a year, which is different from big companies which have to publish their financial reports quarterly. On the other hand, macroeconomic indexes can be obtained from quarterly to daily or even finer, so that most of the macroeconomic indexes can be obtained far more frequently than financial data of small and medium-sized companies. Therefore, we have to consider how to combine these two kinds of data which are different in frequency of being obtained, as input of the default prediction model. This problem has not been discussed in any existing research sufficiently. That is why our research discusses how to use the time-series information of macroeconomic indexes obtained more frequently for default prediction model.

The second point is regarding which indicators are important in default prediction for small and medium-sized companies in each industry sector. There is not much existing research which analyzed and compared properties for small and medium-sized companies by industry sectors, because difficulty of collecting financial data of small and medium-sized companies has made it impossible to analyze properties by industry sectors with sufficient amount of data. However, CRD provided us with such large-scale data, containing financial data of about 1 million companies, that we were able to analyze properties in each industry sector. In this research, we divided companies into eight industry sectors, which will be described in detail in Section 3.2.2, and investigated which financial indicators are important in each industry sector on the basis of variable importance evaluated with random forest.

## 2 Machine Learning for Default Prediction

### 2.1 Default Prediction Models

In the field of default prediction, default prediction models are classified into the following three categories: traditional statistical models, Artificial Intelligence (AI) models, and theoretical models [梅谷 13, 辻 07]. It should be noted that the classification is peculiar to the field of default prediction. We review in this section existing studies which are related with the traditional statistical models and the AI models, both of which are based on statistics and/or machine learning.

Historically, before default prediction models emerged, default prediction was typically performed via calculating financial indicators to measure profitability, safety, and capital efficiency with financial data and comparing the financial indicators with thresholds. Instead of such traditional ratio analysis, Altman proposed in 1968 a default

prediction model on the basis of traditional statistical models [Altman 68]. The proposed model was a multivariate discriminant analysis model, called the Z Score. It was furthermore been extended in 1977 to the ZETA™ Score [Altman 77], which gained popularity and was often used for default prediction. These scores are pioneers of traditional statistical models for default prediction.

Subsequently, logistic model [Flagg 91, 高橋 02, 山下 03, 安道 04, 三浦 08, 森平 09, 山下 11], hazard model [山下 04], and conditional probability model [Goldberg 04] were used for default prediction in existing researches. Strong points of these traditional statistical models are a small amount of calculation and of data needed for learning and high-interpretability because these models are relatively simple. Due to the former point, the traditional statistical models were mainly used when the performance of computers was insufficient and there were no institutions which had a large amount of financial data of companies. However, the traditional statistical models are so simple that their expression capability is poor.

On the other hand, from the middle of 2000s the AI models have been reported to have its higher performance than the traditional statistical models. First, neural network models [Odom 90, Altman 94] were reported as AI models for default prediction. Performance of the neural network models was, however, lower than those of the traditional statistical models because of overfitting. However, in 2000s support vector machines so greatly outperformed the traditional statistical models and the neural network models that the AI models collected a lot of attention [Min 05, Shin 05, Chen 11]. Furthermore, in 2010s, ensemble learning, such as bagging, boosting, and random forest, spread in the field of default prediction, and the AI models, especially ensemble learning and support vector machines, were reported to have the highest performance in many researches [Zhang 10, Kim 10, Wang 11, Barboza 17]. According to the existing researches in the field of default prediction, at present, the best performing models seem ensemble learning and support vector machines. A strong point of the AI models is high expressivity, which leads to higher performance of the AI models than the traditional statistical learning models. Although learning of the AI models needs an enormous amount of calculation and of data, improvement of computing capability and accumulation of financial data about small and medium-sized companies have enabled the AI models to be applied to default prediction. However, the AI models are so complicated that most of them have low interpretability. Highly interpretable models are appropriate to obtain useful information for credit risk evaluation.

### 2.2 Combining Macroeconomics into Default Prediction

In order to use macroeconomic indexes for default prediction models, one should consider which indexes, what forms, and which terms are appropriate for summarizing time-series information of the macroeconomic indexes. In existing researches, discussion of methods summarizing time-series information of macroeconomic indexes is insufficient. For example, means and volatilities<sup>1</sup> of Nikkei

<sup>1</sup>In this paper, the term “volatility” implies historical volatility. The historical volatility  $\sigma$  is defined as  $\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (u_i - \bar{u})^2}$ , where  $N$

225<sup>2</sup> and Yen to US dollar exchange rate over a year to the companies' account closing months are treated as inputs of the default prediction model [大橋 03, Tinoco 13, Nam 08, Alifiah 14], or year-to-year percentage changes of means and volatilities on their account month are treated as the inputs [森平 09], without any basis. In order to use the macroeconomic indexes for the default prediction model, further discussion of which indexes, what forms, and which terms are appropriate for summarizing time-series information of the macroeconomic indexes, is necessary.

First, regarding which indexes should be used for default prediction of small and medium-sized companies, Ogi and Moridaira [尾木 13] used a probit model for default prediction of small and medium-sized companies, with financial data as well as a single postulated background macroeconomic factor as the regressors. They first estimated values of the background macroeconomic factor on the basis of data collected by Tokyo Shoko Research, LTD., and then performed another regression analysis, where the dependent variable is the estimated background factor and where the independent variables are macroeconomic indexes, in order to see what macroeconomic indexes describe the background macroeconomic factor, and consequently, the default probabilities. They reported that the macroeconomic indexes which have influences on corporate default of small and medium-sized companies are short-term interest rate, long-term interest rate, exchange rate, and stock-market indexes.

Second, we should consider what forms are appropriate for summarizing time-series information of the macroeconomic indexes. The forms we considered as summaries of their time-series information are mean, volatility, and percentage change because of the following reasons. The mean of the interest rates and of exchange rate imply information of high-interest or low-interest and of conditions with a strong yen, a strong dollar, and so on, respectively. The volatility is also important because in terms of stock price or exchange rate, even though the mean is the same, if the volatility differs, the interpretation of the economy will differ significantly. The percentage change connotes trends of markets. Even though the mean and the volatility are the same respectively, whether the market is uptrend or downtrend will affect the interpretation of the economy greatly. Hence, the mean, the volatility, and the percentage change are considered appropriate summaries for macroeconomic indexes.

Third, we have to focus on which terms of the mean, the volatility, and the trend should be summarized. The mean and the volatility within a short time interval upto the financial month should be considered as features affecting corporate defaults, because the farther the mean and the volatility are from the financial month, the less influence they might have on a corporate default. On the other hand, the trend within both of a short and a long time intervals upto the financial month should affect corporate defaults, since there is general knowledge that the trend has the following two types: macrotrends and microtrends, both of which are important. Accordingly, we summarize information of the macrotrends and microtrends, and confirm whether the general knowledge is appropriate.

is sample size,  $\bar{u} = \frac{1}{N} \sum_{i=1}^N u_i$ ,  $u_i = \log \frac{S_i}{S_{i-1}}$ , and  $S_i$  is the central rate of  $i$ -th day.

<sup>2</sup>Nikkei 225 © Nikkei Inc.

## 3 Experiments

### 3.1 Purposes

We performed two experiments. In Experiment 1, whose purpose was finding important properties for default prediction, we divided companies into eight industry sectors and investigated which financial indicators are important in each industry sector on the basis of variable importance evaluated with random forest. In Experiment 2, whose purpose was improving the performance of the default prediction, we devised models considering both the macroeconomic indexes and the financial indicators. We then compared the models considering the macroeconomic indexes and the financial indicators and the model with only the financial indicators, in order to see whether or not incorporation of macroeconomic indexes is effective in default prediction.

### 3.2 Model, Industry Sectors, Financial Indicators, and Macroeconomic Indexes Used in The Experiments

#### 3.2.1 Random Forest

Random forest (see, e.g., [Hastie 09]) is one of the ensemble learning models and is reported to achieve high performance of default prediction in existing researches. The procedure of random forest is described in **Algorithm 1**. Random forest also has high interpretability. In the process of learning, random forest measures importance of each input variable, called variable importance. By using the variable importances, the present work investigates important financial indicators in each industry sector.

There are three major parameters in random forest: the number  $B$  of trees in the forest, the maximum depth  $d_{\max}$  of the tree, and the minimum number  $n_{\min}$  of samples required to split an internal node. In this study, these three parameters were determined as 10000, 10000, and 2, respectively, on the basis of preliminary experiments.

The area under the receiver operating characteristic (ROC) curve, abbreviated as AUC, was used for performance evaluation. Given an output  $P(\mathbf{x})$  of the random forest algorithm, as well as test datasets consisting of financial data of default and non-default companies, AUC is estimated as

$$AUC = \frac{1}{n_D n_{ND}} \sum_{i \in D, j \in ND} I(P(\mathbf{x}_i) - P(\mathbf{x}_j) \geq 0), \quad (1)$$

where  $D$  and  $ND$  denote test datasets of default and non-default companies, respectively, where  $n_D$  and  $n_{ND}$  denote the numbers of data of default and non-default companies, respectively, and where  $I(c)$  denotes the indicator function of the condition  $c$ .

---

#### Algorithm 1: Random Forest

- 1: for  $b = 1$  to  $B$ :
    - 2: Draw a bootstrap sample of size  $N$  from the training data
    - 3: Grow a random-forest tree  $T_b$  to the bootstrapped data, by recursively repeating the following steps for each terminal node of the tree, until the maximum depth of the tree  $d_{\max}$  or the minimum node size  $n_{\min}$  is reached:
      - 4: (i) Select  $m$  variables at random from the  $p$  variables
      - 5: (ii) Pick the best variables/split-point among the  $m$  variables
      - 6: (iii) Split the node into two daughter nodes
    - 7:  $T_b$  can calculate the probability  $P_b(\mathbf{x})$  of classifying  $\mathbf{x}$  into the positive class
  - 8: Output:  $P(\mathbf{x}) = (\sum_{b=1}^B P_b(\mathbf{x})) / B$
-

Table 1: The numbers of all default data and all non-default data by industry sectors in 2010–2016.

Industry Sectors	Default Companies	Non-Default Companies
Construction	2991	793457
Manufacturing	2868	723275
Information and Communication	343	59759
Wholesale and Retail	4229	901999
Real Estate and Goods Leasing	612	257299
Accommodation and Food Service	977	124278
Lifestyle-related Entertainment	319	58268
Medical and Welfare	199	91924

### 3.2.2 Industry Sectors

In financial data provided by CRD, each company is labeled with the industry sector to which it belongs. In this work, we chose the following eight industry sectors: construction industry, manufacturing industry, information and communication industry, wholesale and retail industry, real estate and goods leasing industry, accommodation and food service industry, lifestyle-related entertainment industry, and medical and welfare industry.

The numbers of default companies and non-default companies in the dataset are shown in Table 1. Since there were only a few of default companies, we adjusted the number of non-default companies in order to avoid the class imbalance problem. In each industry sector, we used all the default data and 100 times as many non-default data as the default data. The non-default data used in our experiments were chosen randomly.

### 3.2.3 Financial Indicators

In assessment for credit risk of a company, there are many financial indicators measuring profitability, safety, and capital efficiency. In this work, we chose the following 18 financial indicators: sales to total assets (総資産売上率), return on equity (自己資本当期利益率), ratio of gross profit to sales (売上高総利益率), operating profit on sales (売上高営業利益率), ratio of ordinary profit to sales (売上高経常利益率), current ratio (流動比率), quick assets ratio (当座比率), fixed ratio (固定比率), fixed assets to fixed liability ratio (固定長期適合率), debt ratio for total assets (借入金依存度), SGA ratio (売上高販管比率), inventory turnover period (棚卸資産回転日数), accounts receivable turnover period (売上債権回転日数), trade payable turnover period (買入債務回転日数), tangible fixed assets turnover rate (有形固定資産回転率), ratio of depreciation to sales (売上高減価償却率), and interest coverage ratio, ratio of interest-bearing debt to cash-flow (キャッシュフロー有利子負債比率). These financial indicators were treated as inputs of random forest.

### 3.2.4 Macroeconomic Indexes

In view of the analysis by Ogi and Moridaira [尾木 13] mentioned in Section 2.2, which states that the macroeconomic indexes which have influences on default probabilities of small and medium-sized companies are short-term interest rate, long-term interest rate, exchange rate, and stock-market indexes, we chose in this research the following macroeconomic indexes: unsecured overnight

call rate<sup>1</sup>, 1-year Japanese Government Bond<sup>2</sup>, 10-year Japanese Government Bond<sup>2</sup>, Yen to US dollar exchange rate<sup>1</sup>, Yen to Euro exchange rate<sup>1</sup>, and Nikkei 225<sup>3</sup>.

We summarized unsecured overnight call rate and Japanese Government Bonds in terms of the following five elements: mean of the rate in financial month and percentage changes in one/three/six/twelve months up to financial month. Therefore, there are 15 elements summarizing unsecured overnight call rate, 1-year Japanese Government Bond, and 10-year Japanese Government Bond, altogether.

We summarized exchange rates in terms of the following six elements: mean of the rate in financial month, percentage changes in one/three/six/twelve months up to financial month, and volatility in financial month. Therefore, there are 12 elements summarizing Yen to US dollar exchange rate and Yen to Euro exchange rate, altogether.

Since only monthly data are available for Nikkei 225, we summarized Nikkei 225 in terms of the following six elements: mean of the highest price and the lowest price in financial month, percentage changes in one/three/six/twelve months up to financial month, and volatility index<sup>4</sup> of Nikkei 225 in financial month. As above, by using the percentage changes in various periods, time-series information of macroeconomic indexes can be summarized.

In total, these 33 elements of macroeconomic indexes were treated as inputs of random forest.

## 3.3 Experiment 1: Analyzing Important Financial Indicators by Industry Sectors

### 3.3.1 Premise

In Experiment 1, only the financial indicators were used as inputs of the default prediction model, the macroeconomic indexes not being used. For each industrial sector, random forest was learned on the basis of financial data only and we predicted whether each company would go into default or not in a year from financial month. Financial data, account closing months of which were in 2010, 2011, 2013, and 2015, were used as training data, and financial data, account closing months of which were in 2012, 2014, and 2016, were used as test data. The numbers of default and non-default companies used in Experiment 1 by industry sectors and by financial years, are shown in Table 2. On the basis of variable importance of the financial indicators evaluated with random forest, we considered influential financial indicators on corporate default by industry sectors.

### 3.3.2 Results

The variable importances of the 18 financial indicators are shown in Figure 1 by industry sectors. In this work, we repeated the calculation 50 times. The performance of random forest will be shown in Section 3.4, where the model used in Experiment 1 is referred to as Model 1.

<sup>1</sup>Source of data is the website of Bank of Japan Time-Series Data Search (<https://www.stat-search.boj.or.jp/>). We are permitted to use data for non-commercial purposes.

<sup>2</sup>Source of data is the website of Ministry of Finance ([https://www.mof.go.jp/jgbs/reference/interest\\_rate/index.htm](https://www.mof.go.jp/jgbs/reference/interest_rate/index.htm)). We are permitted to use data for non-commercial purposes.

<sup>3</sup>Source of data is Nikkei 225 Official Site (<https://indexes.nikkei.co.jp/nkave/index>). We obtained permission from Nikkei Inc. to use data of Nikkei 225.

<sup>4</sup>Source of data is volatility index of Nikkei 225 Official Site (<https://indexes.nikkei.co.jp/nkave/index>). We obtained permission from Nikkei Inc. to use data of Nikkei 225.

### 3.3.3 Discussion

In all the industry sectors except the information and communication industry, the most or second most important variable is quick assets ratio. This result corresponds to common knowledge that quick assets ratio is the more appropriate indicator than current ratio for the rigid evaluation for short-term safety. On the other hand, the reason that quick assets ratio has a not high variable importance in the information and communication industry is that information and communication business does not need so much inventory that current ratio and quick assets ratio are almost the same.

In all the industry sectors, debt ratio for total assets is also important, which is the most, second most, or third most important variable in the construction industry, the manufacturing industry, the information and communication industry, the wholesale and retail industry, and the real estate and goods leasing industry. Additionally, in other three industry sectors variable importance of the debt ratio for total assets is not low. The result that the debt ratio for total assets is important is as we expected. On the other hand, in all the industry sectors ratio of depreciation to sales has a low variable importance: the ratio of depreciation to sales has the lowest importance in the construction industry, the manufacturing industry, the wholesale and retail industry, the accommodation and food service industry, and the lifestyle-related entertainment industry and not high importance in the other three industry sectors. The ratio of depreciation to sales is difficult to use to make rules, such that the higher the indicator is, the safer the company is. Our result confirmed the properties. Consequently, the ratio of depreciation to sales should be focused on in comparison of a company with a few other companies in the same industry sector.

The ratio of interest-bearing debt to cash-flow is an indicator implying how long it takes to return interest-bearing debt in current cash flow of the company. Industry sectors where the importance of the ratio of interest-bearing debt to cash-flow is high are the manufacturing industry and the real estate and goods leasing industry. In these two industry sectors the initial investment is costly, e.g. buying large-scale equipment in the manufacturing industry and purchasing real estates. Our result implies whether the initial debt can be returned or not has a large influence on corporate default in the manufacturing indus-

Table 2: The numbers of default (D) and non-default (ND) companies used in Experiments 1 and 2, by industry sectors and by financial years.

Industry Sectors	2010		2011	
	D	ND	D	ND
Construction	246	42786	255	42754
Manufacturing	255	40897	206	40906
Information and Communication	26	4925	29	4864
Wholesale and Retail	257	60498	254	60376
Real Estate and Goods Leasing	86	8674	65	8692
Accommodation and Food Service	78	13961	106	13918
Lifestyle-related Entertainment	22	4559	26	4554
Medical and Welfare	8	2839	10	2762

2012		2013		2014		2015		2016	
D	ND								
226	42546	279	42965	250	42596	584	42780	1151	42673
245	40862	274	40918	308	41221	584	40972	996	41024
28	4918	40	4927	36	4941	79	4848	105	4877
305	60411	351	60666	402	60421	939	60320	1721	60208
54	8755	59	8763	64	8762	115	8794	169	8760
97	13966	114	14019	95	13963	191	14004	296	13869
30	4591	31	4573	34	4572	57	4525	119	4526
17	2832	16	2879	20	2923	43	2882	85	2783

try and the real estate and goods leasing industry.

On the other hand, accounts receivable turnover period is an indicator implying how many days it will take for the accounts receivable to become cash. Only in the information and communication industry, the importance of accounts receivable turnover period is high. The reason is considered that companies in the information and communication industry have so few assets that can be cashed quickly that the companies cannot repay the debts when accounts receivable turnover period is extended.

Lastly, trade payable turnover period is an indicator representing how many days it will take to return the purchase obligation on the basis of ratio of accounts and bills payable to sales. In the same way as the ratio of depreciation to sales, the trade payable turnover period is also difficult to use to make rules, such that the higher the indicator is, the safer the company is. That is why the importance of the trade payable turnover period is low in seven out of the eight industry sectors. However, in the accommodation and food service industry, the trade payable turnover period is the second most important indicator. Although we could not find any clear explanation for that, the trade payable turnover period should be focused on in default prediction for companies in the accommodation and food service industry.

## 3.4 Experiment 2: Comparison Between Models Considering Only Financial Indicators and Considering Also Macroeconomic Indexes

### 3.4.1 Premise

In Experiment 2, not only the financial indicators but also macroeconomic indexes were used as inputs of the default prediction model. We devised the following three random forest models. Model 1 takes as input only the 18 financial indicators. Model 2 takes as input the 18 financial indicators and the following 15 elements of macroeconomic indexes: mean of the rate in financial month and percentage change in one year up to financial month, of unsecured overnight call rate and Japanese Government Bonds, mean of the rate in financial month, percentage change in one year up to financial month, and volatility in financial month, of Yen to US dollar and Yen to Euro exchange rates, and mean of the highest price and the lowest price in financial month, percentage change in one year up to financial month, and volatility index of Nikkei 225 in financial month, of Nikkei 225. Model 3 takes as input the 18 financial indicators and all the 33 elements of macroeconomic indexes listed in Section 3.2.4. Models 1, 2, and 3 predicted whether each company would go into default or not in a year from financial month. Financial data, account closing months of which were in 2010, 2011, 2013, and 2015, were used as training data, and financial data, account closing months of which were in 2012, 2014, and 2016, were used as test data. Also in Experiment 2, the models learned the training data of each industry sector, and conducted default prediction for companies in the same industry sector. The default and non-default companies used in Experiment 2 were the same as those used in Experiment 1. The numbers of default and non-default companies used in Experiment 2 by industry sectors and by financial years, are shown in Table 2.

Table 3: Comparison of model performance measured by AUC, industry by industry, in Experiment 2. The results of AUC are shown by mean and standard deviation (SD) multiplied by  $10^{-3}$  through 50 calculations.

Industry Sectors	Model 1		Model 2		Model 3	
	Mean	SD	Mean	SD	Mean	SD
Construction	0.776	0.756	0.808	0.505	0.815	0.678
Manufacturing	0.823	0.618	0.847	0.542	0.850	0.525
Information and Communication	0.764	2.56	0.789	1.75	0.798	1.60
Wholesale and Retail	0.813	0.724	0.841	0.544	0.844	0.431
Real Estate and Goods Leasing	0.780	1.98	0.790	1.29	0.795	1.41
Accommodation and Food Service	0.760	1.67	0.767	0.990	0.771	1.15
Lifestyle-related Entertainment	0.744	2.67	0.772	1.38	0.764	1.75
Medical and Welfare	0.727	3.34	0.759	2.20	0.771	1.92

### 3.4.2 Results

Comparison of the performance of the models measured by AUC is shown in Table 3 and in Figure 2, where the mean and the standard deviation over 50 trials are shown. These imply that random forest learned the training data and predicted whether each company in the test data would go into default or not in a year from financial month.

### 3.4.3 Discussion

By comparison of Model 1 and Model 2 in all the industry sectors, we confirmed that considering macroeconomic indexes improves the default prediction model for small and medium-sized companies.

In terms of comparison of Model 2 and Model 3, Model 3 outperformed Model 2 in seven out of the eight industry sectors except the lifestyle-related entertainment industry. Additionally, there was a significant difference between AUC of Model 2 and Model 3 on the basis of Mann Whitney U test, all p values of which were lower than  $1.0 \times 10^{-17}$  in all the seven industry sectors. From this result, considering both of microtrends and macrotrends improves the default prediction model for small and medium-sized companies in the seven industry sectors. Although we could not find any clear explanation for the lower performance of Model 3 than Model 2 in the lifestyle-related entertainment industry, we considered that the reason would be the insufficient amount of data in the lifestyle-related entertainment industry. In the lifestyle-related entertainment industry, there are a wider variety of companies than in any other industry sectors, such as barber shops, tour businesses, movie theaters, and fitness clubs. Therefore, it should be different from a company to another how the macroeconomic factors affect on the default of the company. In order to classify the wide variety of companies, the sufficient amount of data is essential. It is true that there were a large amount of financial data provided by CRD. However, focusing on only the number of companies in the lifestyle-related entertainment industry, there were only a few amount of data, as shown in Table 2. With a sufficient amount of data in the lifestyle-related entertainment industry, the models will learn appropriately and we can improve the default prediction model for small and medium-sized companies by considering both of microtrends and macrotrends, in the lifestyle-related entertainment industry.

## 4 Conclusion

We have studied improvement of the default prediction model for small and medium-sized companies by consid-

ering not only their financial data but also macroeconomic indexes and regarding which financial indicators are important by industry sectors in default prediction for small and medium-sized companies. As a result, the default prediction model with inputs of the financial indicators and the macroeconomic indexes outperformed the model with inputs of only financial indicators. Furthermore, the model, to the inputs of which the percentage changes in the fine periods summarizing microtrends added, outperformed the model not considering the percentage changes in the fine periods. Therefore, considering macroeconomic indexes, especially our proposed method summarizing both macrotrends and microtrends, has been found effective for default prediction. Furthermore, we investigated which financial indicators are important by industry sectors.

Although the results of investigating which financial indicators are important by industry sectors presented in Section 3.3 gave us useful insights for default prediction for small and medium-sized companies, the knowledge obtained from the results does not include which macroeconomic indexes are important by industry sectors. The reason of this is that on the basis of variable importance in random forest, the variable importances of macroeconomic indexes turned out to be so lower than those of financial indicators that we were not able to consider which macroeconomic indexes are important by industry sectors. In order to consider which macroeconomic indexes are important by industry sectors, appropriate approaches for this purpose should be considered.

On the other hand, in terms of macroeconomic indexes, another interesting question would be as to which periods one should take in summarizing them into the mean, the volatility, and the trend. Although this paper considered some periods within one year, wider or finer periods, or both, should be considered. Moreover, this research set the base period of macroeconomic indexes as financial month. However the base period should be discussed in more detail. We conjecture that the appropriate base period of macroeconomic indexes would be different by industry sectors. Discovery of the appropriate base period by industry sectors will improve the default prediction for small and medium-sized companies further.

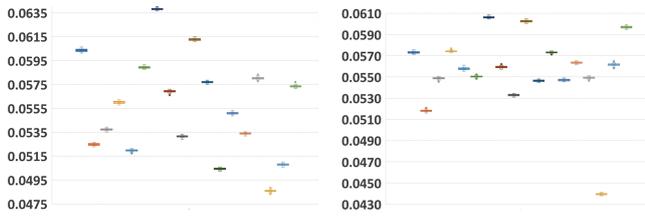
## Acknowledgment

We would like to thank Professor Hideaki Aoyama, Graduate School of Science, Kyoto University, Kyoto, Japan, for his valuable advice and managing financial data, and the CRD institution for providing their data.

## References

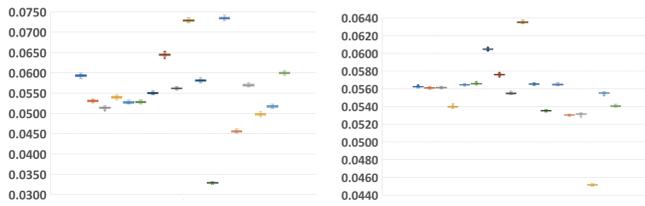
- [Ali 10] Ali, A. and Daly, K.: Macroeconomic determinants of credit risk: Recent evidence from a cross country study, *International Review of Financial Analysis*, Vol. 19, No. 3, pp. 165–171 (2010)
- [Alifiah 14] Alifiah, M. N.: Prediction of financial distress companies in the trading and services sector in Malaysia using macroeconomic variables, *Procedia-Social and Behavioral Sciences*, Vol. 129, pp. 90–98 (2014)
- [Altman 68] Altman, E. I.: Financial ratios, discriminant analysis and the prediction of corporate bankruptcy,

- The Journal of Finance*, Vol. 23, No. 4, pp. 589–609 (1968)
- [Altman 77] Altman, E. I., Haldeman, R. G., and Narayanan, P.: ZETA™ analysis: A new model to identify bankruptcy risk of corporations, *Journal of Banking & Finance*, Vol. 1, No. 1, pp. 29–54 (1977)
- [Altman 94] Altman, E. I., Marco, G., and Varetto, F.: Corporate distress diagnosis: Comparisons using linear discriminant analysis and neural networks (the Italian experience), *Journal of Banking & Finance*, Vol. 18, No. 3, pp. 505–529 (1994)
- [Barboza 17] Barboza, F., Kimura, H., and Altman, E.: Machine learning models and bankruptcy prediction, *Expert Systems with Applications*, Vol. 83, pp. 405–417 (2017)
- [Bonfim 09] Bonfim, D.: Credit risk drivers: Evaluating the contribution of firm level information and of macroeconomic dynamics, *Journal of Banking & Finance*, Vol. 33, No. 2, pp. 281–299 (2009)
- [Chen 11] Chen, S., Härdle, W. K., and Moro, R. A.: Modeling default risk with support vector machines, *Quantitative Finance*, Vol. 11, No. 1, pp. 135–154 (2011)
- [Chen 14] Chen, P. and Wu, C.: Default prediction with dynamic sectoral and macroeconomic frailties, *Journal of Banking & Finance*, Vol. 40, pp. 211–226 (2014)
- [Flagg 91] Flagg, J. C., Giroux, G. A., and Jr, C. E. W.: Predicting corporate bankruptcy using failing firms, *Review of Financial Economics*, Vol. 1, No. 1, pp. 67–78 (1991)
- [Goldberg 04] Goldberg, L. R. and Giesecke, K.: Forecasting default in the face of uncertainty, *The Journal of Derivatives*, Vol. 12, No. 1, pp. 14–25 (2004)
- [Hastie 09] Hastie, T., Tibshirani, R., and Friedman, J.: *The Elements of Statistical Learning*, Springer, 2nd edition (2009)
- [Kim 10] Kim, M.-J. and Kang, D.-K.: Ensemble with neural networks for bankruptcy prediction, *Expert Systems with Applications*, Vol. 37, pp. 3373–3379 (2010)
- [Min 05] Min, J. H. and Lee, Y.-C.: Bankruptcy prediction using support vector machine with optimal choice of kernel function parameters, *Expert Systems with Applications*, Vol. 28, pp. 603–614 (2005)
- [Nam 08] Nam, C. W., Kim, T. S., Park, N. J., and Lee, H. K.: Bankruptcy prediction using a discrete-time duration model incorporating temporal and macroeconomic dependencies, *Journal of Forecasting*, Vol. 27, No. 6, pp. 493–506 (2008)
- [Odom 90] Odom, M. D. and Sharda, R.: A neural network model for bankruptcy prediction, *IEEE International Joint Conference on Neural Networks*, pp. 163–168 (1990)
- [Shin 05] Shin, K.-S., Lee, T. S., and Kim, jung H.: An application of support vector machines in bankruptcy prediction model, *Expert Systems with Applications*, Vol. 28, pp. 127–135 (2005)
- [Tinoco 13] Tinoco, M. H. and Wilson, N.: Financial distress and bankruptcy prediction among listed companies using accounting, market and macroeconomic variables, *International Review of Financial Analysis*, Vol. 30, pp. 394–419 (2013)
- [Wang 11] Wang, G. and Ma, J.: Study of corporate credit risk prediction based on integrating boosting and random subspace, *Expert Systems with Applications*, Vol. 38, pp. 13871–13878 (2011)
- [Zhang 10] Zhang, J. L. and Hardle, W. K.: The Bayesian additive classification tree applied to credit risk modelling, *Computational Statistics and Data Analysis*, Vol. 54, pp. 1197–1205 (2010)
- [安道 04] 安道 知寛, 山下 智志: 財務指標の時間依存を考慮した信用リスク評価モデル—デフォルト予測への応用, 金融庁ディスカッションペーパー (2004)
- [高橋 02] 高橋 久尚, 山下 智志: 大規模データによるデフォルト確率の推定—中小企業信用リスク情報データベースを用いて—, 統計数理, Vol. 50, No. 2, pp. 241–258 (2002)
- [三浦 08] 三浦 翔, 山下 智志, 江口 真透: 信用リスクスコアリングにおける AUC と AR 値最大化法, 金融庁ディスカッションペーパー (2008)
- [山下 03] 山下 智志, 川口 昇: 大規模データベースを用いた信用リスクの計測の問題点と対策 (変数選択とデータ量の関係), 金融庁ディスカッションペーパー (2003)
- [山下 04] 山下 智志, 安道 知寛: 時間依存共変量を用いたハザードモデルによるデフォルト確率期間構造の推計手法, 統計数理, Vol. 54, No. 1, pp. 23–38 (2004)
- [山下 11] 山下 智志: 与信判断が確率変動するときの倒産企業の信用リスク値分布のモデル, 統計数理, Vol. 59, No. 1, pp. 3–23 (2011)
- [森平 09] 森平 爽一郎, 岡崎 貫治: マクロ経済効果を考慮したデフォルト確率の期間構造推定, 日本ファイナンス学会第 17 回大会予稿集, pp. 103–112 (2009)
- [大橋 03] 大橋 亨: 企業倒産とマクロ経済要因—企業倒産についての重回帰モデルの構築—, 現代社会文化研究, Vol. 28, pp. 47–67 (2003)
- [辻 07] 辻 正雄, ヴァチェスラフジュロフ: 企業倒産予知モデルの構築と比較分析, 産業経理, Vol. 67, No. 1, pp. 4–17 (2007)
- [梅谷 13] 梅谷 幸平: 経営管理目的からの倒産予測モデル研究の有用性と課題: 経営管理のための安全性指標の観点から, 大阪大学経済学会, Vol. 62, No. 4, pp. 63–83 (2013)
- [尾木 13] 尾木 研三, 森平 爽一郎: 中小企業のデフォルト率に影響を与えるマクロ経済要因—1 ファクターモデルを用いたアプローチ—, 日本政策金融公庫論集, No. 20, pp. 71–89 (2013)



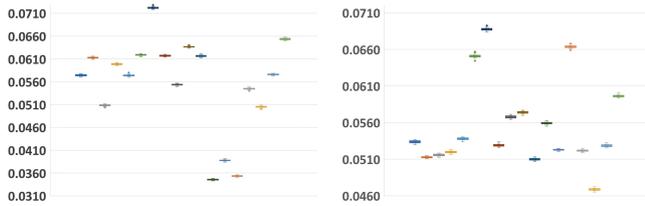
(a) Construction Industry

(b) Manufacturing Industry



(c) Information and Communication Industry

(d) Wholesale and Retail Industry



(e) Real Estate and Goods Leasing Industry

(f) Accommodation and Food Service Industry



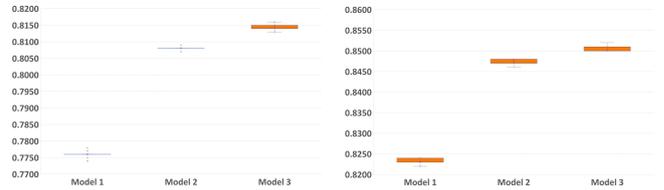
(g) Lifestyle-related Entertainment Industry

(h) Medical and Welfare Industry



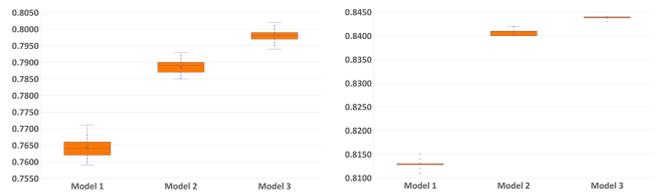
(i) Legend of The Above Graphs

Figure 1: Comparison of variable importances of 18 financial indicators calculated by random forest in Experiment 1. Each box plot shows the distribution of variable importance through 50 calculations.



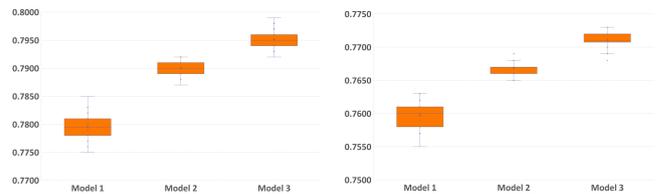
(a) Construction Industry

(b) Manufacturing Industry



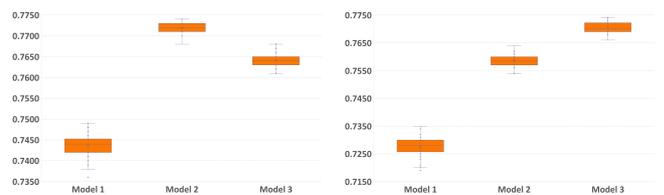
(c) Information and Communication Industry

(d) Wholesale and Retail Industry



(e) Real Estate and Goods Leasing Industry

(f) Accommodation and Food Service Industry



(g) Lifestyle-related Entertainment Industry

(h) Medical and Welfare Industry

Figure 2: Comparison of random forest performance by industry sectors in Experiment 2. Each box plot shows the distribution of AUC through 50 calculations.

# オプションアプローチによる中小企業の現金残高の推測

## Cash Prediction for Small and Medium Enterprises by Option Approach

薄井研二<sup>1\*</sup>  
Kenji Usui<sup>1</sup>

<sup>1</sup>freee 株式会社  
<sup>1</sup>freee K.K.

**Abstract:** Abstract: Cash management is important to avoid cash-shortage, especially for Small and Medium Enterprises(SME) due to lack of excess cash. Whereas, cash management at SME is not sufficient because of its complexity and high cost. Therefore, we investigate a convenient method to predict a time to cash-shortage and an amount of shortage by Option Approach.

In this study, We calculates a probability of default by using Option Approach, regarding its “asset” and “debt” as cash amount and any amount respectively. We evaluated Area Under Curve (AUC) by changing a prediction term, debt amount and calculation term of asset. We found several facts: max AUC is 0.81, short prediction term or large cash decrease makes high AUC, and calculation term is very small relation to AUC.

As a result, Option Approach can predict a cash of SME in short term or large change. This approach is useful for cash management of SME to decide an acceptable debt amount and terms.

## 1 はじめに

企業活動において資金繰りは重要な課題である。資金繰りの重要性を示す一例として黒字倒産の問題が挙げられる。黒字倒産とは利益がでていても支払い時に現預金残高の不足で債務不履行となり倒産することである。この黒字倒産の対策は金融機関などから融資を受け一時的に現預金を確保する方法が一般的だろう。そのために、企業では入出金予定や債権債務の管理を行い資金状態を把握し融資を受けるタイミングや額を決定している。

黒字倒産の発生は大企業よりも中小企業において顕著であり、中小企業庁の発表 [1] によると黒字倒産する企業の 93% は 20 人以下の中小企業に起きている。中小企業の黒字倒産が多い原因として、余剰資金が少ないことに加え資金繰りのオペレーションコストが高いため十分に行われていないことが挙げられる。そのため、簡便に将来の資金不足のタイミングや額を知る方法の価値は高い。そこで、一般に企業の活動は 1 年を周期として類似していることが多いことから、過去のデータを用いることで資金不足のタイミングや額を確率的に予測することが可能なのではないかと考えた。すな

わち、過去の現預金残高残高の変動から将来の現預金残高の分布を予測するということである。本研究では、現預金残高を資産価値とすることで株式価格が不明な中小企業にオプションアプローチを応用した。

オプションアプローチとは、株式が企業価値を原資産とするコールオプションであるとみなし市場で得られる株式価格や企業の財務データを用いることでデフォルト確率を求める手法である [2]。オプションアプローチが統計アプローチに比べて優れている点は株式価格はマーケットという市場参加者による合意形成がなされた場で決定されリアルタイムに得られるという点である。一方で、株式価格が計算に必要なため上場企業など株式が公開されている企業でないと利用することができない。そのため未上場企業へのデフォルト率計算に用いられることはなかった。本研究では、オプションアプローチにおける資産を現預金残高残高とし負債を任意の金額としたときの推測精度を評価することで、将来の現預金残高の予測可能性を調べた。

## 2 手法とデータ

### 2.1 計算方法

まず、一般的なオプションアプローチについて計算式を示す。現在が  $t$  期で負債の満期が  $T$  期であるとき

\*連絡先: freee 株式会社  
東京都品川区西五反田 2-8-1 五反田ファーストビル 9F  
E-mail: kusui@freee.co.jp

のデフォルト確率  $PD(T)$  は下記式で求められる [2]。 $N(-d_2)$  は満期時において資産が負債を下回る確率であり、 $A_t$ :  $t$  期の資産価値、 $D_T$ : 満期  $T$  の負債総額、 $\mu_A$ : 資産の期待成長率、 $\sigma_A$ : 資産の標準偏差である。

$$PD(T) = N(-d_2) = N\left(-\frac{\ln(A_t/D_T) + (\mu_A - \sigma_A^2/2)(T-t)}{\sigma_A\sqrt{(T-t)}}\right)$$

提案手法では中小企業の現預金残高を推測する必要がある。そこで上式における資産価値は現預金残高、負債は任意の数値と置き換えて計算を行う。つまり  $T$  期に任意の金額に対して現預金残高が下回る確率を求める。資産の標準偏差と期待成長率の算出方法は複数存在するが、本研究では標準偏差は資産価値の過去の月次現預金残高データより月次の変化額から標準偏差を算出し、期待成長率は過去の月次現預金残高の変動率から平均値を算出した。

## 2.2 実験データ

従来、中小企業の現預金残高や会計データは各社のシステムに散在しており複数の会社をまたいだ調査を行うことは難しく、金融機関では法人の現預金すべてを把握することは困難であった。そこで、今回は free株式会社が個人事業主や中小企業向けに提供し、100万事業所に利用されている（2018年3月発表）クラウド会計ソフト freee[3] のデータを用いた。これはクラウド型のシステムであるため事業所の会計データはこのシステム上に集積されており網羅的な分析が可能である。また、決算書ではなく会計データそのものを保持しているため年次よりも細かい粒度の分析が可能である。本研究では月次の現預金残高を貸借対照表の月次推移より取得した。この月次推移は各月末の値である。分析対象は未上場の法人とし、より正確なデータを用いるため有料プランを使用している法人のデータのみを使用した。データの対象期間は、2017年度のデータを精度検証の対象として用い、2016年度以前を資産の期待成長率および標準偏差を計算するために使用した。

## 3 評価と考察

オプションアプローチによる現預金残高の推測精度は  $A_T$  が  $D_T$  を下回っている状態を擬似デフォルトと定義して AUC を算出して評価する。AUC の算出には法人の月次現預金残高一年分を元にパラメータ  $\sigma_A$  と  $\mu_A$  から  $D_T$  に対して  $PD$  を算出、その次の一期をテストデータとした。

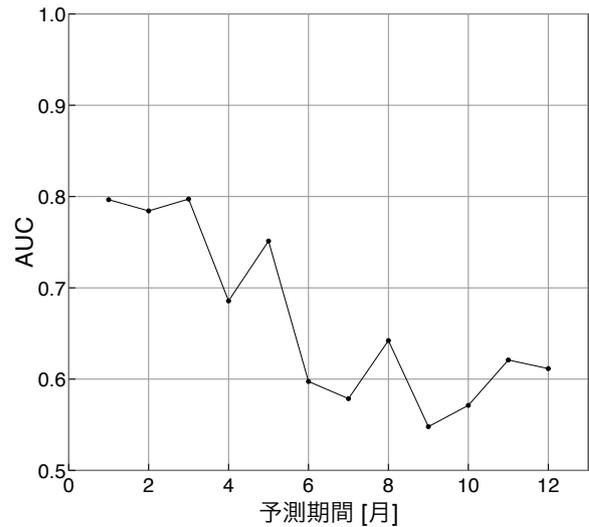


Fig. 1: 予測期間 [月] に対する AUC の変化

### 3.1 予測期間

まず、高い予測精度の得られる期間を特定するために、予測期間  $T-t$  の変動による推測精度の変化を調べる。実用上、より長期の予測が可能であるほど資金不足に融資や支払いサイトの変更など対策を余裕をもって実行できるなど有用性が高い。予測期間を 1-12ヶ月に変化させたときの AUC を算出してその変化を調べた。このとき  $D_T$  は  $A_t$  の 50% と定義して計算を行った。一般にオプションアプローチでは  $T$  および  $t$  の単位は期であるが、本研究では資金繰りを考える際にはできるだけ短期の方が望ましく、月次の財務諸表が取得できるため月とした。

計算結果を Fig. 1 に示す。予測期間が 1-12ヶ月の範囲において AUC は 0.61-0.80 となった。AUC は予測期間が 1ヶ月のとき最も高く予測期間が 9ヶ月のときに最も低くなった。特に予測期間が 1-3ヶ月という短期の領域では AUC が 0.79 と高い値が得られた。予測期間が 1-9ヶ月の領域において予測期間が増加するに連れて AUC が低下する傾向が見られた。予測期間が更に長い 9ヶ月以上の領域において AUC は飽和もしくは増加している傾向が見られた。この結果から、予測期間は短いほうがよりも精度が高く、特に 1-3ヶ月の領域は精度が高いことがわかった。

### 3.2 現預金残高率

次に、 $D_T$  の変化による推測精度の変化を調べた。予測期間を 3ヶ月と固定し、 $D_T$  を  $A_t$  の  $n\%$  と定義したときの  $n$  を 10-90 に 10 刻みで変化させたときの AUC の変化を調べた。事業者の立場で考えたとき、将来の

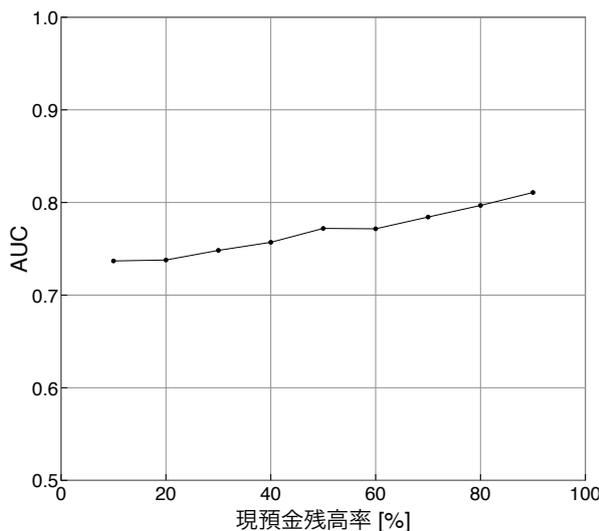


Fig. 2: 現預金残高率 [%] に対する AUC の変化

支払い予定に必要な現預金を確保できる確率や、現預金を安定して確保するために極端な減少などの発生確率を知ることは重要である。

計算結果を Fig. 2 に示す。n が 10-90% の領域において AUC は 0.73-0.81 という結果が得られた。n が 90% のとき AUC は 0.81 と最も高く n が 0.1 のとき AUC は 0.71 で最も低い値となった。n と AUC の関係は Fig. 2 より、n が増加するにつれて AUC が増加する関係にあることが見えた。すなわち現在の現預金残高から離れた値のほうが推測精度が高い。これは極端な現預金残高の変動を予測する精度が高いことを示しており有用性が高いといえる。

### 3.3 パラメータ計算対象期間

最後に、計算に必要なデータ期間を調べるために、資産の期待成長率と標準偏差を計算する期間を 1-3 年で変動させてそれぞれ AUC を算出した。計算の結果、AUC は 0.79 で変化は極めて小さかった。この結果から複数年度において標準偏差や資本の期待成長率の大きな変化が生じていないことが予想される。

上記の結果を総合して検証する。結果をまとめると、予測期間が変化すると AUC は減少する傾向があり予測期間が 1-3ヶ月の短期の領域では AUC は 0.79 前後で高い精度が得られた。D<sub>T</sub> に対する予測精度の変化は D<sub>T</sub> が現在の現預金残高から離れるにつれて精度が向上する傾向が見られ、AUC は 0.73-0.81 であった。最後に  $\sigma_A$  や  $\mu_A$  の計算対象期間を 1-3 年に変化させたときの AUC の変化は極めて小さかった。以上から、短期の現預金残高において極端に現預金変動する場合

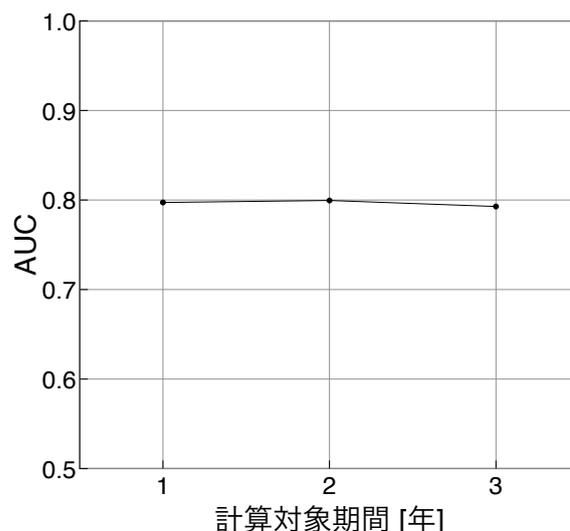


Fig. 3: パラメータ計算対象期間 [年] に対する AUC の変化

ほど高い精度で推測でき、その場合は前期 1 年程度のデータがあればよいことが示唆された。

## 4 まとめ

本研究では中小企業における資金繰りの煩雑さを解決するためオプションアプローチによる現預金残高予測の可能性を検討した。資産として現預金残高を、負債として現預金残高の一定割合を指定し、オプションアプローチを用いたデフォルト率を算出し、実際の現預金残高の変動と比較を行った。オプションアプローチにおけるデフォルト率計算式の変数とパラメータのうち予測期間や負債額、成長率や標準偏差の計算対象期間などを変動させながら精度を評価した。結果、今回の実験の範囲では、短期予測ほど精度が高く、極端な変動ほど推測精度が高いことがわかった。また、資産の成長率や標準偏差の計算対象期間は精度に大きな影響を与えないことがわかった。これは事業者から見ると、直近の前期 1 年間のデータを用いることで短期間かつ大きな現預金残高の変動ほど高い精度で予測できるということであり、例えば出金予定に対する資金の枯渇の確率を簡便に知ることができる。多忙な中小企業の事業主にとって資金繰りの負担を軽減する手段の一つとなりえるだろう。

## 参考文献

[1] 中小企業庁: 2017 年版中小企業白書, (2017)

- [2] 森平爽一郎: 信用リスクモデリング -測定と管理-,  
(2009)
- [3] クラウド会計ソフト freee:  
<https://www.freee.co.jp/> [2019/02/13]

# 銀行間と企業間の多層ネットワークシミュレーションを用いた 企業投資の影響分析

Analysis of Investment Effect  
Using Multilayer Networks Simulation among Banks and Companies

濱脇 諒\*<sup>1</sup> 尾崎 順一\*<sup>2</sup> 和泉 潔\*<sup>1</sup> 島田 尚\*<sup>1</sup> 松島 裕康\*<sup>1</sup> 坂地 泰紀\*<sup>1</sup>  
Ryo Hamawaki Junichi Ozaki Kiyoshi Izumi Takashi Shimada Hiroyasu Matsushima Hiroki Sakaji

\*<sup>1</sup>東京大学大学院 工学系研究科  
School of Engineering, The University of Tokyo

\*<sup>2</sup>東京工業大学 科学技術創成研究院  
Institute of Innovative Research, Tokyo Institute of Technology

Recent globalism of economic makes the effect of a certain small bankruptcy enhance internationally beyond of the area and country. So, we propose the model in which the interaction between banks and companies is focused and simulate and consider the effect of whether banks invest the funds or not to the growth of companies. In particular, by varying the width of change of the growth rate of companies according to whether they are invested, we researched the difference in the distribution of the final size of companies. The model of banks is based on actual data such as financial statement analysis edited by Japanese Bankers Association. As the results, the investment of banks did not raise the mean of growth rate but widened the disparity in size among companies. As future plans, we'd like to reproduce and analyze the cause of large chain bankruptcy using the extended model.

## 1. はじめに

近年の経済のグローバル化により、特定の企業や業界で起こった破綻や倒産のリスクがその業界および国を超えて国際的に影響を与えることが起きている。これらはシステミックリスクと呼ばれ、関連する研究が近年注目を浴びている [永田 13].

システミックリスクに関わる研究として、銀行間ネットワークに着目した研究がある。今久保ら [今久保 08] では、銀行間のコール市場におけるネットワーク構造の特徴を明らかにしている。橋本ら [橋本 17] では、複数の種類のネットワークを用いて、破綻の連鎖を説明し、予測を行なっている。前野 [前野 13] では、各銀行が貸借対照表を持つことで、資金貸出先の倒産による自己資本の毀損によって銀行が連鎖的に倒産していく様子を再現し、連鎖倒産リスクが高くなる条件をまとめている。また、企業についても、田村ら [田村 14] は企業間での活動に着目し企業間の発注下請け関係をリンクとしたネットワークとして見ることで、資金の流れに着目する研究を行なっている。

しかし、今久保らは銀行のネットワークについての実証研究でありシミュレーションの研究は行っていない。橋本らは銀行のみのシミュレーションであり、銀行の主業務である融資についての考慮がなされていない。前野では独自のモデルで銀行のバランスシートを作成して、現実のデータと整合性が取れるかの検証がなされていない。企業についても、田村らは銀行に触れておらず、企業のみ活動に着目して、銀行との融資関係までをモデル化したものは少ない。

そこで、本研究では、銀行と企業の活動の相互作用に着目したモデルを提案し、銀行からの投資の有無が企業の成長に与える影響についてシミュレーションした結果を考察する。

## 2. モデル

本モデルは、大きく分けて 3 つの構成要素から成る: 1. 銀行 100 行; 2. 企業 100 社; 3. 株式市場 40 銘柄。

銀行に関する詳細については、2.1 節と 2.2 節、企業については 2.4 節、株式市場については 2.3.2 節の中で述べていく。

### 2.1 銀行間ネットワーク

銀行間ネットワークは銀行同士の貸借関係を表したものであり、各銀行をノードとし貸借関係をリンクとしている。本モデルでは、コアペリフェラルネットワークを用いて実験を行う。コアペリフェラルネットワークは実際の日本における銀行間の貸借関係で観測されたもので [今久保 08], 以下のような特徴を持つネットワークである: 1. コアと周辺という 2 重構造; 2. コア内は完全ネットワークに近い; 3. コアは周辺に対するハブとなっている; 4. 周辺はクラスター化している。

銀行  $i$  から銀行  $j$  への初期の貸借額  $Lend_{i,j}$  は式 1 を用いて算出した [前野 13].

$$Lend_{i,j} = \frac{out_{k_i}^r \cdot in_{k_j}^r}{\sum_{i=1}^N \sum_{i \neq j} out_{k_i}^r \cdot in_{k_j}^r} L \quad (1)$$

ここで、 $out^{(in)}_{k_i}$  は銀行  $i$  が貸出 (借入) を行っている銀行数、 $N$  は総銀行数、 $L$  は総貸出数、 $r$  は貸借額の偏りを表しているパラメータである。式 1 は自分の貸出先が多ければ多いほど、また、貸出先の借入先が多ければ多いほど貸出額が大きくなることを意味している。

### 2.2 貸借対照表

各銀行は資金の貸し借りや株式市場のような有価証券の管理を貸借対照表を用いて管理する。今回使用する項目は以下の 7 つである

(借方)	(貸方)
有価証券	自己資本
現金	預金
企業貸出	
銀行間貸出	銀行間借入

図 1: 貸借対照表の項目

まず、式 1 で各銀行間の貸出と借入が決定される。

次に、全国銀行協会が公表している全国銀行財務諸表分析より、日本における銀行の貸借対照表をもとにノンパラメトリック手法であるカーネル密度法を用いて実データから有価証券、現金、自己資本、預金の割合を決定する。

## 2.3 銀行と企業の連携

### 2.3.1 銀行から企業への貸出

銀行は 1 年に一度余剰資金を企業へ貸し出す。余剰資金 *surplus* は式 2 によって決定される。

$$\begin{aligned} surplus &= \left\{ [現金] + \min \left( 0.5 [有価証券], \frac{15.0}{85.0} [現金] \right) \right\} \\ &= -\{0.05 (0.6 [預金]) + 0.4 (0.4 [預金]) \\ &\quad + 0.3 (0.35 [企業貸出])\} \end{aligned} \quad (2)$$

式 2 は国際決済銀行が世界の銀行に求めているバーゼル規制に基づくものであり、流動性破綻を防ぐため、最低限持つべき現金の量を表している。本モデルでは、この量の半分を 1 年に 1 度企業に貸し出すこととしている。

また、その貸出先は規模が上位 30 社の企業の中からランダムに決定される。

### 2.3.2 株式市場とファンダメンタル価格

本モデルには株式市場が存在し、40 種類の銘柄が各銀行によって売買されている。この売買には鳥居らのモデル [鳥居 15] を使用していて、各銀行はその銘柄の本質的な価値と値動きのトレンドを見て取引を行う。

各株式の時刻  $t$  における価格  $p_t$  は式 3 によって決定される。

$$p_t^i = p_{t-1}^i + \alpha(n_{b,t-1}^i - n_{s,t-1}^i) + \beta growthrate_{t-1}^i \quad (3)$$

$n_{b,t}^i$  は時刻  $t$  に購入された株式  $i$  の数、 $n_{s,t}^i$  は時刻  $t$  に売却された株式  $i$  の数、 $growthrate_t^i$  は時刻  $t$  における企業  $i$  の成長率を表している。需給の差と成長率に比例して価格が変動するモデルとなっている。 $\alpha, \beta$  はそれぞれ需給の差と成長率の影響を統制する定数であり、今回は全ての実験において一定としている。

## 2.4 企業の成長モデル

各企業は 1 年に一度以下の分布にしたがって生成された値を成長率として規模を拡大させる。この成長率は 1 年毎の企業の規模の対数差分として定義する。企業の成長率  $g$  の分布  $P(g)$  は坂井ら [坂井 12] によると以下の分布に従うことが知られている。

$$P(g) = \frac{2V}{\sqrt{g^2 + 2V}(|g| + \sqrt{g^2 + 2V})} \quad (4)$$

$V$  は以上の分布の分散を表すパラメータである。以上の分布は、 $g \rightarrow 0$  付近ではラプラス分布に従い、 $g \rightarrow \infty$  ではべき分布で近似されることを意味している。また、規模の大きな企業は分布の中央に多く、テール部分には規模の小さな企業の成長率が反映されている。

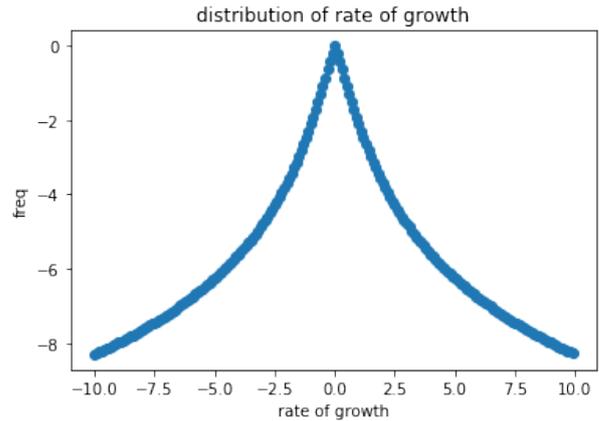


図 2: 企業の成長率の分布

## 3. シミュレーション

### 3.1 実験の目的

各企業の規模に焦点を当てる。

一般に、企業は設備拡張や新規事業開発のために銀行から融資を受け資金を調達する。この投資による影響として、銀行の主業務の 1 つである融資が企業の成長にどのような作用をするのかを調べ、モデルの妥当性を検証する。

### 3.2 実験の詳細

シミュレーションは図 3 のフローに従って行われる。

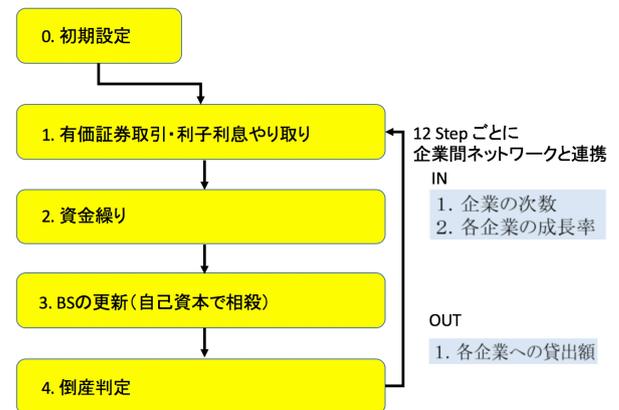


図 3: 貸借対照表の項目

図で示されるフローを 1 ステップとし、これを 12 ステップ繰り返す。12 ステップ終了後に前述のアルゴリズムにしたがって、各銀行は企業へ貸し出す額を決定する。その貸出額を受け取って各企業の成長率が決定され、成長率から企業の規模が求められる。以上の行動を 1 セットとして本シミュレーションでは 10 セット行う。

10 セット終了後の企業の規模の分布について以下の 3 パターンの成長率の決定方法で実験し比較を行う。

成長率は 2.4 節で述べた確率分布から取得するが、平均 0 の両側何% の範囲で乱数が動くかを変化させる。

1. 両側 20%
2. 企業の規模 *size* に反比例する値  $width = \frac{1}{2\sqrt{size}}$

### 3. パターン 2. に投資の額に応じた係数を加算した値

企業の投資の 1 つである設備投資は一般に、供給力の増大が期待される一方で、在庫リスクの拡大や市場の効率性が損なわれる可能性がある [比佐 07]。これをモデルに組み込むため、パターン 3. の投資の額に応じた係数は、小規模の投資の時 5%、大規模の投資の時 7.5% とし、投資の規模が大きくなるにつれて、不安定な成長となるモデルとした。

各実験を 30 試行ずつ行い、最終的な企業の規模の初期値からの成長率を調べた。また、それぞれのパターンの成長率の分布について、正規分布と言えるかどうかを調べる Shapiro-Wilk 検定を行った。

### 3.3 実験結果

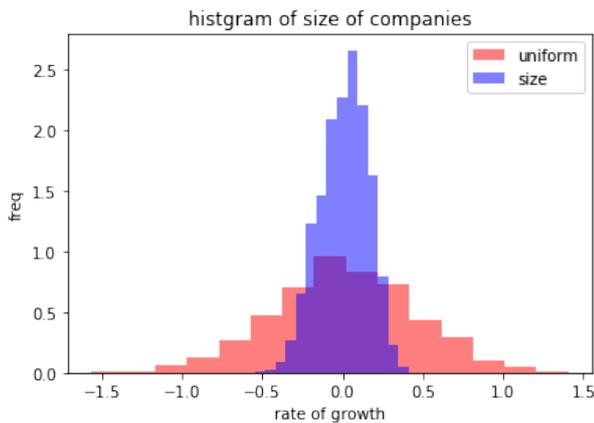


図 4: 成長率の頻度分布の比較その 1

図 4 は、パターン 1(uniform) の時とパターン 2(size) の時の最終的な成長率の頻度分布を正規化したものである。パターン 1 では成長率が  $-1.0$  から  $1.0$  の範囲で正規分布の様な分布で広がっているのに対し、パターン 2 では  $0$  付近の値に集中する結果となった。

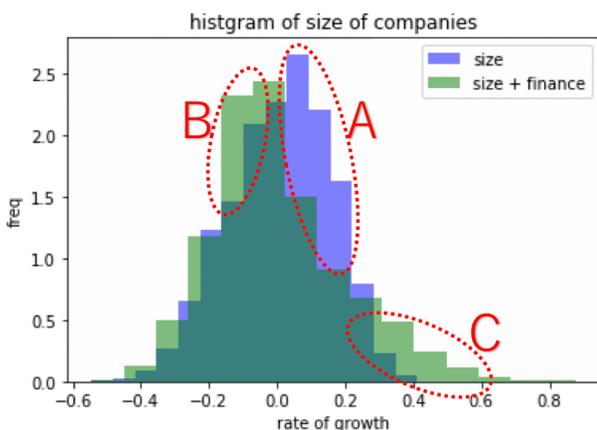


図 5: 成長率の頻度分布の比較その 2

図 5 は、パターン 2(size) の時とパターン 3(size + finance) の時の最終的な成長率の頻度分布を正規化したものである。パターン 2 よりもパターン 3 の方が最頻値が負の方向に移動していることが見て取れる。平均値もパターン 2 の時が  $0.0078$ 、パターン 3 の時が  $0.0025$  であり、若干ではあるが減少していた。

次に、各パターンについて Shapiro-Wilk 検定の結果を示す。それぞれの  $p$  値は表 3.3 のとおりであった。

表 1: 各パターンにおける Shapiro-Wilk 検定の  $p$  値

	パターン 1	パターン 2	パターン 3
$p$ 値	0.282	$1.51 \times 10^{-15}$	$8.3 \times 10^{-32}$

## 4. 考察

### 4.1 パターン 1 と 2 の比較

まず、パターン 1 の時とパターン 2 の時の差異について考察を行う。本モデルでは成長率を各年の規模の対数差分としているため、 $n$  年の成長率を  $g_n$  とすると、10 年目の各企業の規模  $size_{10}$  は以下の様に表される。

$$size_{10} = size_0 e^{g_1} e^{g_2} \dots e^{g_{10}} = size_0 e^{\sum_{k=1}^{10} g_k} \quad (5)$$

さらに、パターン 1 においては  $g_k$  は図 2 の中心から両側 20% の同じ分布から成長率を取得している。よって、中心極限定理より式 5 の指数部分は正規分布に従うことが示され、シミュレーションの結果も表 3.3 より、Shapiro-Wilk 検定の  $p$  値が  $0.05$  より大きくなっており、正規分布であるという帰無仮説は棄却されず、整合的な結果となっている。

一方で、パターン 2 の時は企業の規模の初期値を  $100$  としたため、大抵の企業が安定的な成長しかせず、大きく成長するものや急速に規模が縮小する様なものが現れず、 $g = 0$  の周辺に集中してしまったと言える。Shapiro-Wilk 検定の  $p$  値も  $0.05$  より小さくなり、正規分布であるという帰無仮説は棄却される。

### 4.2 パターン 2 と 3 の比較

次に、パターン 2 の時とパターン 3 の時について考察を行う。パターン 3 もパターン 2 と同様に企業の規模が成長率に影響を与えるモデルであるので、 $g = 0$  の周辺に成長率が集中していることが言え、また、Shapiro-Wilk 検定より正規分布であるという帰無仮説も棄却される。

しかし、図 5 を見るとパターン 2 とパターン 3 の分布に差異を確認することができる。それは赤い点線で囲まれた 3 つのエリアである。パターン 2 では観測されるエリア A の分布がパターン 3 ではエリア B とエリア C に移動している。この部分が投資による成長率への影響と考え、考察を行う。

4.1 節で行なった考察をもとに考えると、エリア A にあった企業は規模が大きく安定的な成長をしていた企業である。本モデルでは、銀行が余剰資金を投資している企業は規模の上位 30 社としたため、エリア A の企業も投資対象になりうる。

ここで、投資を受けた時企業は高いリターンを得られるかもしれない一方で、規模が縮小してしまうかもしれないリスクを負う様なモデルとしたため、エリア A にいた企業が成長を遂げることができ、エリア B に移動したものと規模が縮小しエリア C に移ったものの 2 つに分かれたことが図 5 からうかがえる。

そこで、パターン 2 とパターン 3 の平均値を比較してみると、パターン 2 の方が若干大きくなったものの最終的な企業の規模に変換するとパターン 2 の時が  $100.8$  に対し、パターン 3 の時が  $100.3$  となり、大差はなかったことがわかる。つまり、本モデルでは銀行の企業への投資は企業の集合全体での成長率の平均には影響を与えないが、企業の成長率の分布には影響を与え、企業間での格差が広がる方向に作用するという結果となった。

## 5. まとめと将来の展望

### 5.1 まとめ

本研究では、銀行と企業の相互作用について研究を行うためのモデルの提案とそれを用いた実験を行った。

モデルとしては、銀行間ネットワークの作成に日本のコール市場に見られた特徴を反映したコアペリフェラルネットワークを用い、各銀行の貸借対照表は全国銀行協会の全国銀行財務諸表分析の分布をもとに作成し、データ・ドリブン志向のモデルを構築した。

また、このモデルを使った実験では銀行から企業への投資が企業の成長率にどのような影響を与えるかについて、シミュレーションを行った。その結果、銀行の投資は企業の成長率に対して、全体の平均を上げ成長を促すという効果は得られなかったが、企業間の格差を拡大させるという結果となった。具体的には、投資を受けて成長できた企業とそうでなかった企業の2群に分布が分かれた様子が確認された。

### 5.2 将来の展望

将来の展望としては、今回時間依存しない確率モデルで成長率をおいた企業側の部分のモデルについて、銀行間ネットワークと同様にエージェントベースのシミュレーションに拡張する。各企業をノードとし、企業同士の活動をリンクとしたネットワークを作り、企業同士の相互作用も考慮することが狙いとなっている。これにより、ある企業への銀行の投資がその企業とつながっている企業への好影響をもたらし、投資の影響が伝播していく様子や反対に、投資していた企業の倒産が銀行の倒産を招き、大きな連鎖倒産を引き起こしてしまうといったシステムリスクが生じるメカニズムを再現し分析できる。

## 参考文献

- [永田 13] 永田 裕司：システムック・リスクと金融の脆弱性，福岡大学商学論叢，Vol. 57, No. 3-4, pp. 253-272 (2013)
- [橋本 17] 橋本 守人，倉橋 節也：資金取引ネットワークモデルに基づく連鎖破綻リスク分析，人工知能学会論文誌，Vol. 32, No. 5, pp. B-H21.1 (2017)
- [今久保 08] 今久保 圭，副島 豊：コール市場の資金取引ネットワーク，金融研究，Vol. 27, No. 2, pp. 47-100 (2008)
- [坂井 12] 坂井 功治，渡辺 努：企業成長率分布の統計的性質と含意，経済学論集，Vol. 78, No. 3, pp. 2-13 (2012)
- [前野 13] 前野 義晴：金融システムを安定化する最適な投融资ポートフォリオと銀行間ネットワーク，人工知能学会 金融情報学研究会 (2013)
- [鳥居 15] 鳥居 拓馬，中川 勇樹，和泉 潔：複数資産人工市場を用いた裁定取引によるショック伝搬の分析，人工知能学会全国大会論文集 2015 年度人工知能学会全国大会 (第 29 回) 論文集，pp. 1J4OS13a2-1J4OS13a2 一般社団法人 人工知能学会 (2015)
- [田村 14] 田村 光太郎，高安 美佐子：企業間取引ネットワーク上でのお金の流れのモデル化とシミュレーション，シミュレーション，Vol. 33, No. 4, pp. 262-268 (2014)
- [比佐 07] 比佐 章一：日本企業における設備投資行動の不安定性とその決定要因-横並び行動の検証と所有構造の影響，日本経済研究，No. 57, pp. 1-22 (2007)

# 人工市場を用いた金融市場流動性に影響を与える要因の調査

## Investigation of factors influencing market liquidity using artificial market

益田 裕司<sup>1\*</sup>                      水田 孝信<sup>2</sup>                      八木 勲<sup>3</sup>  
Yuji Masuda<sup>1</sup>                      Takanobu Mizuta<sup>2</sup>                      Isao Yagi<sup>3</sup>

<sup>1</sup> 神奈川工科大学大学院工学研究科情報工学専攻

<sup>1</sup> Course of Information and Computer Sciences, Graduate School of Kanagawa Institute of Technology

<sup>2</sup> スパークス・アセット・マネジメント株式会社

<sup>2</sup> SPARX Asset Management Co. Ltd

<sup>3</sup> 神奈川工科大学情報学部

<sup>3</sup> Faculty of Information Technology, Kanagawa Institute of Technology

### Abstract:

近年、市場の「流動性」に関心が集まっている。流動性は金融市場の盛況を表す尺度とされる。流動性が高ければ、市場参加者は市場の中間価格に近い価格で意図した数量を円滑に売買することができるため、流動性は「取引のしやすさ」ととらえることもできる。実証研究では、それぞれの研究目的に沿うよう流動性指標を定義し、その有用性を議論してきた。しかし、どのような市場要因がこれらの指標に影響を与えるのかは明確にされていない。そこで本研究では、人工市場を用いて、どの市場要因が主要な流動性指標 (Volume, Tightness, Resiliency, Depth) にどのような影響を与えるのか、指標間にどのような相関性があるのか調査する。さらに実証研究では計測困難な価格の復元速度 (Resiliency) についても調査する。

## 1 まえがき

金融市場の盛況を表す目安とされる「流動性」に関心が集まっている。一般に流動性が高い市場とは、その時々で観察される『市場価格』に近い価格で、市場参加者が売りたい (あるいは買いたい) 量を、速やかに売れる (あるいは買える) 市場が想定されることが多い [6]。

流動性に関する研究は、特に実証研究の分野で多数行われ、さまざまな知見が得られている。例えば、Kyle[7] は、(1) "Tightness", 買い手と売り手の提示価格の差, (2) "Depth", (3) "Resiliency" を含む多くの概念を使用し流動性を評価することを提案した。Amihud[1] は、1日の株式収益率の絶対値を取引金額で割った値を非流動性の尺度として提案し (ILLIQ), 資産の期待収益が流動性によって増加することを示した。しかしながら、何をもちいて流動性とみなすかは実証研究の調査目的ごとに異なることが多い。例えば、市場価格のボラティリティの大きさや、市場参加者の売買が市場価格に大きな影響を及ぼさないことを流動性と結びつけることも多い。その結果、流動性を計測するために使用される指標

は研究間で異なることが多く、ある研究で得られた流動性の結果が他の研究で得られた結果と一致しているかどうかを分析することは困難である。

このように実証研究では対処困難なものに対応する手法の1つに、人工市場を用いる手法がある。人工市場は、社会シミュレーションの1つであり、計算機上に仮想的に構築されたマルチエージェントシステムの金融市場のことを指す [2], [3], [8]。人工市場におけるエージェントは仮想的な投資家であり、現実の投資家の特性がモデルとして組み込まれている。そして、エージェントらに金融資産の取引をさせることで市場がどのように振舞うかを確認することができる。また、市場側に規制や制約 (例えば、空売り規制のような市場の安定性と効率性を確保するための制限) をモデル化して組み込むことで、エージェントの振る舞いや市場にどのような影響が現れるかを検証することもできる。

これまでの人工市場を用いた研究では、いくつかの有用な知見が得られている [14], [15]。しかしながら、人工市場シミュレーションを用いた研究では、流動性そのものに着目した研究は行われていない。

そこで本研究では、人工市場のパラメータを変更して流動性指標間の関連を調査する。つまり、市場価格のティックサイズなどの人工市場内のパラメー

\*連絡先: 神奈川工科大学大学院工学研究科情報工学専攻  
神奈川県厚木市下荻野 1030  
E-mail: s1885003@cco.kanagawa-it.ac.jp

タを変更することで、どの市場要因が主要な流動性指標 (Volume, Tightness, Resiliency, Depth) にどのような影響を与えるのか、指標間にどのような相関性があるのか調査する。さらに実証研究では計測困難な価格の復元速度 (Resiliency) についても調査する。

本論文の構成は以下のとおりである。2章では市場流動性とは何かについて説明する。3章では本研究で用いた人工市場モデルについて説明する。4章では本研究で行う実験の詳細や得られた結果について説明する。最後に5章では、本研究のまとめと今後の課題について述べる。

## 2 流動性

### 2.1 流動性の定義

市場流動性は確立された唯一の定義というものは存在していない。しかし、一般的に「流動性の高い市場とは、大口の取引を小さな価格変動で速やかに執行できる市場である」[16]といわれている。流動性を計測する実証研究では、4つの評価軸 (Volume, Tightness, Resiliency, Depth) がよく使用されている [11]。

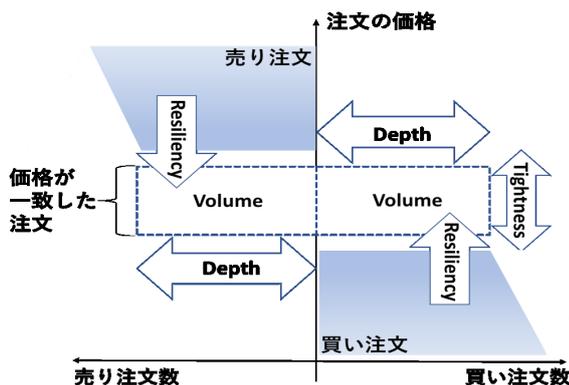


図 1: 流動性の概念整理 [11]

#### 2.1.1 Volume

Volume は市場での取引量である。一定期間内に市場全体で取引された株式数である出来高は Volume の指標とすることができる。出来高が大きいと、頻繁な取引や短期間で大量の取引が容易になる。そのため、出来高が大きければ流動性が高いといえる。本研究では、出来高を Volume として計測する。

#### 2.1.2 Tightness

Tightness は買い手と売り手の提示価格の差である。買い手の1番高い注文の価格である最良買い気配 (ベスト・ビッド) と売り手の1番安い注文であ

る最良売り気配 (ベスト・アスク) の乖離幅として定義されるビッド・アスク・スプレッドがよく用いられる。提示価格の差が狭ければ、市場参加者の意図する価格から離れず取引が行える。そのため、ビッド・アスク・スプレッドが小さいほど流動性は高いといえる。本研究では、シミュレーション期間内のビッド・アスク・スプレッドの平均を Tightness として計測する。

#### 2.1.3 Resiliency

Resiliency は市場の復元力である。取引が成立し、上下した市場価格が元の価格に戻る早さのことを指す。価格に大きな騰落が起きた場合でも、迅速に騰落前の価格へ戻ると、取引を迅速かつ円滑に行える。そのため Resiliency は小さければ、流動性が高いといえる。

本研究では、従来の計測法である値幅・出来高比率 [11] と、これまで計測困難であった価格の復元速度を Resiliency として計測する。

値幅・出来高比率は、日中の市場価格の最高値と最小値の幅を1日の出来高で除した指標で、その日の取引での平均的な価格変化を示している。取引が成立することで板に残っている注文が少なくなり板が薄くなっても、市場に復元力があれば速やかに板は回復し、売買に伴う価格変化は小さくなる。そのため、1つの取引の平均的な価格変化である値幅・出来高比率が小さければ、市場の流動性は高いといえる。

価格の復元速度は、何らかの影響で価格が大きく変化した際、実勢価格まで戻るのに要する時間にて表す。この時間が短いほど流動性は高いといえる。

#### 2.1.4 Depth

Depth はベスト・ビッド、ベスト・アスクに近い価格で出されている注文量であり、実際の注文の量を示す。ベスト・ビッド、ベスト・アスクに近い価格での注文量が多い状況を市場が厚い状況と呼ぶ。市場に厚みがあれば、市場参加者が意図した価格と市場価格との差が小さくなる。また市場に残っている注文が多く、取引成立した際の市場価格が振れにくくなる。そのため、Depth が大きければ、流動性が高いといえる。本研究では、シミュレーション期間内のベスト・ビッド (アスク) から 50 高い (安い) 注文の合計の量の平均を Depth として計測する。

## 3 人工市場モデル

### 3.1 市場構成

本研究では、Mizuta ら [9] の人工市場モデルを基に、人工市場モデルの構築をおこなった。

本モデルは、1つの資産のみを取引対象とする。エージェントは  $n$  体おり、エージェント  $j = 1$  から、 $j = 2, 3, 4, \dots$  と順番に注文を出す。最後のエージェント  $j = n$  が注文を出すと、次の時刻にはまた

はじめのエージェント  $j = 1$  が注文を出していく。時刻  $t$  はエージェント 1 体が注文を出すたびに、1 だけ増える。つまり、注文をただけで取引が成立しない場合も 1 ステップ進む。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取引が成立する、連続ダブルオークション方式（サラバ方式）とした。ティックサイズを  $\Delta P$  とし、注文価格を求めるときに  $\Delta P$  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。買い注文価格より安い売り注文、または売り注文より高い買い注文が注文板に既に存在していれば、取引が即時成立する。取引が成立しなかった場合は注文を残す。本研究では、取引が即時成立する注文を成行注文、市場に残る注文を指値注文と呼ぶ。市場に残した指値注文が注文有効期間  $t_c$  だけ経過しても取引が成立せず残っていた場合、注文板から取り除く。注文数は常に 1 とした。各エージェントが持つキャッシュ量は無限とし、資産を何単位でも買うことができる。また空売りも可能とした。

### 3.2 エージェントの注文プロセス

エージェントは以下の手順に従い、注文価格、買いと売りの判断を行う。エージェント  $j$  が時刻  $t$  のときに予想する価格の変化率（予想リターン） $r_{e_j}^t$  は式 (1) で求める。

$$r_{e_j}^t = \frac{1}{w_{1,j}^t + w_{2,j}^t + u_j} \left( w_{1,j}^t \log \frac{P_f}{P^{t-n}} + w_{2,j}^t r_{h_j}^t + u_j \epsilon_j^t \right) \quad (1)$$

ここで、 $w_{1,j}^t$  は時刻  $t$  におけるエージェント  $j$  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  $w_{i,max}$  までの一様乱数で決める。この重みは、後で述べる学習プロセスにより変化する。 $u_j$  は時刻  $t$  におけるエージェント  $j$  の 3 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  $u_{max}$  までの一様乱数で決められ、シミュレーション中に変化することはない。 $P_f$  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で取引された価格であり、時刻  $t = 0$  では  $P^t = P_f$  とする）であり、 $\epsilon_j^t$  は時刻  $t$ 、エージェント  $j$  の乱数項で、平均 0、標準偏差  $\sigma_e$  の正規分布乱数である。 $r_{h_j}^t$  は時刻  $t$  に、エージェント  $j$  が計測した過去リターンであり、 $r_{h_j}^t = \log(P^{t-n}/P^{t-(n+\tau_j)})$  である。ここで  $\tau_j$  は、シミュレーション開始時に 1 から  $\tau_{max}$  までの一様乱数でエージェントごとに決める。

式 (1) の第 1 項目はファンダメンタル価値を参照し投資判断を行うファンダメンタル投資家の成分であり、ファンダメンタル価格と直前期の市場価格を比較し、市場価格が安ければプラス、高ければマイナスの予想リターンを表す。第 2 項目は過去の価格推移を参照し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ならプラス、マ

イナスならマイナスの予想リターンを表す。第 3 項目はノイズの成分を表す。

予想リターン  $r_{e_j}^t$  より予想価格  $P_{e_j}^t$  は式 (2) で求める。

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

注文価格  $P_{o_j}^t$  は平均  $P_{e_j}^t$ 、標準偏差  $P_\sigma$  の正規分布乱数で決める。ここで、 $P_\sigma$  は式 (3) で求める。

$$P_\sigma = P_{e_j}^t \times Est \quad (3)$$

$Est$  ( $0 < Est \leq 1$ ) を便宜上、「ばらつき係数」と呼ぶ。買いと売りの判断は予想価格  $P_{e_j}^t$  と注文価格  $P_{o_j}^t$  の大小関係で決まる。

$$\begin{aligned} P_{o_j}^t > P_{e_j}^t &\text{なら 1 単位の買い} \\ P_{o_j}^t < P_{e_j}^t &\text{なら 1 単位の売り} \end{aligned} \quad (4)$$

### 3.3 学習プロセス

状況に応じて戦略を切り替えるという学習プロセスを Yagi ら [14] のモデルを参考にモデル化した。学習はエージェントごとに注文の直前におこなわれ、ファンダメンタル投資家の場合の予想リターンを  $r_{e_{1,j}}^t = \log(P_f/P^{t-1})$ 、テクニカル投資家の場合の予想リターンを  $r_{e_{2,j}}^t = r_{h_j}^t$  とする。これら  $r_{e_{i,j}}^t$  を学習期間のリターン  $r_l^t = \log(P^t/P^{t-t_l})$  と比較し、式 (5) のように  $w_{i,j}^t$  を書き換える。

$$\begin{aligned} \text{同符号なら, } w_{i,j}^t &\leftarrow w_{i,j}^t + k_l |r_l^t| q_j^t (w_{i,max} - w_{i,j}^t) \\ \text{異符号なら, } w_{i,j}^t &\leftarrow w_{i,j}^t - k_l |r_l^t| q_j^t w_{i,j}^t \end{aligned} \quad (5)$$

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。式 (5) では、価格変化の方向の予測が現実と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 (5) の学習プロセスの他に、確率  $m$  で  $w_{i,j}^t$  を 0 から  $w_{i,max}$  までの一様乱数にて再設定を行う。

## 4 シミュレーション結果

### 4.1 実験概要

3 章でモデル化した人工市場を用いて実験を行う。各パラメータ値を変更して流動性の評価軸 (Volume, Tightness, Resiliency, Depth) の変動を検証する。

実験で用いるモデルでは、以下のパラメータを用いた。具体的には、 $n = 1000$ ,  $w_{1,max} = 1$ ,  $w_{2,max} = 10$ ,  $u_{max} = 1$ ,  $\tau_{max} = 10,000$ ,  $\sigma_e = 0.06$ ,  $Est = 0.003$ ,  $t_c = 20,000$ ,  $\Delta P 1.0$ ,  $P_f = 10,000$ ,  $m = 0.01$  とした。またシミュレーションは時刻  $t = t_{end}$  まで

1,000,000 までおこなった。このうち、変更するパラメータとその値を表1に示す。パラメータは1つ1つ変化させ、変更しないパラメータについては基準パラメータ値に固定している。各種パラメータ値でそれぞれ5試行を行い、後述する Volume, tightness, Resiliency, Depth を算出し、以後それらの平均値を求める。

本人工市場の妥当性については Yagi et al.[13] を参照のこと。

表 1: 変更するパラメータと設定

パラメータ	値				
$\Delta P$	0.1	1.0	10	100	
$\sigma_e$	0.02	0.04	0.06	0.08	0.1
$w_{1,max}$	1.0	3.0	5.0	8.0	
$w_{2,max}$	3.0	5.0	8.0	10	
$Est$	0.003	0.005	0.01	0.02	0.03
$t_c$	10,000	15,000	20,000	30,000	

## 4.2 実験結果

### 4.2.1 ティックサイズ $\Delta P$ 変更実験

ティックサイズ  $\Delta P$  を、0.1, 1.0, 10.0, 100.0 と変化させたときの Volume, Tightness, Resiliency, Depth の平均を表2に示す。ティックサイズが大きくなると、Volume の値は小さくなり、Tightness, Resiliency, Depth の値は大きくなる。

以下にこのようになった理由を述べる。

まず、Volume (出来高) が小さくなった理由は次の通りである。例として、ティックサイズ  $\Delta P = 1$  の場合で考える。予想価格が 10000、注文価格を  $P$  とする。このとき、 $P$  の値が  $10000 < P < 10001$  で売り注文になったとすると、 $P$  の  $\Delta P$  より小さい端数は切り上げられるため、10001 の売り注文となる。また、 $P$  の値が  $9999 < P < 10000$  で買い注文になったとすると、 $P$  の  $\Delta P$  より小さい端数は切り捨てられ、9999 の買い注文となる。その結果、10000 には注文が入らず、10001 と 9999 に注文は入る。つまり、市場に注文が入らない範囲が存在する。この範囲はティックサイズが大きくなるほど広がり、注文が成立しにくくなるため、Volume は小さくなった。

次に、Tightness (ビッド・アスク・スプレッド) が大きくなった理由は、ビッド・アスク・スプレッドの最小値は、0 の場合を除くとティックサイズの値と等しくなるため、ティックサイズが大きくなるとビッド・アスク・スプレッドも大きくなるからである。

さらに、Resiliency (値幅・出来高比率) が大きくなった理由は次のとおりである。値幅・出来高比率の分子は、1日の市場価格の最大値と最小値の差であり、この値の変化の最小値はティックサイズと同じである。ティックサイズが大きくなるにつれて、値幅・出来高比率の分子の最小値も大きくなる。分母の出来高も減少傾向にあるが、ティックサイズの

増加率に比べるとはるかに小さいため、ティックサイズが大きくなると値幅・出来高比率も大きくなる。

最後に、Depth が大きくなった理由だが、取引成立回数が少ないということは、注文板上の指値注文が多くなる。そのため、Depth は大きくなる。

表 2:  $\Delta P$  変更実験

$\Delta P$	Volume	Tightness	Resiliency	Depth
0.1	267,618	12.167	0.0106	2,322.12
1.0	266,285	12.510	0.0107	2,366.39
10	266,535	17.481	0.0117	2,448.53
100	252,734	98.389	0.0190	3,041.21

### 4.2.2 ノイズ成分の予想リターン計算 $\epsilon_j^t$ に用いる定数 $\sigma_e$ 変更実験

ノイズ成分の予想リターン計算  $\epsilon_j^t$  に用いる定数  $\sigma_e$  を 0.02, 0.04, 0.06, 0.08, 0.10 と変化させたときの Volume, Tightness, Resiliency, Depth の平均を表3に示す。 $\sigma_e$  が大きくなる (ノイズ成分の影響が強くなる) と、Volume, Tightness, Resiliency の値は大きくなり、Depth の値は小さくなる。

このようになった理由は Yagi et al.[13] に詳細に記載されているためそちらを参照のこと。

表 3:  $\sigma_e$  変更実験

$\sigma_e$	Volume	Tightness	Resiliency	Depth
0.02	151,673	5.352	0.0061	5,640.79
0.04	225,328	9.177	0.0082	3,566.54
0.06	266,285	12.510	0.0107	2,366.39
0.08	296,942	15.920	0.0136	1,650.04
0.1	319,288	19.339	0.0171	1,243.16

### 4.2.3 ファンダメンタル成分の重みの最大値 $w_{1,max}$ 変更実験

ファンダメンタル成分の重みの最大値  $w_{1,max}$  を 1.0, 3.0, 5.0, 8.0 と変化させたときの Volume, Tightness, Resiliency, Depth の平均を表4に示す。本実験では 4.2.2 節の実験とは逆の結果が得られた。すなわち、 $w_{1,max}$  が大きくなる (ファンダメンタル戦略の比重が大きくなる) と、Volume, Tightness, Resiliency の値は小さくなり、Depth の値は大きくなる。

以下にこのようになった理由を述べる。

まず、Volume が小さくなった理由は次の通りである。ファンダメンタル成分の重みが大きくなると、予想価格をファンダメンタル価格へ収束させようと

する傾向が強くなる。予想価格がファンダメンタル価格へ収束しようとして下落(上昇)してくると、取引が成立しうる成行買い(売り)注文の数は減少する。そのため出来高は減少する。

次に、Tightness が小さくなった理由は以下の通りである。予想価格がファンダメンタル価格へ収束しようとして下落(上昇)してくると、指値注文として市場に出される注文の価格はファンダメンタル価格周辺に集中する。そのため、必然的にベスト・ビッドとベスト・アスクの価格の幅は小さくなる。さらに上述のように Volume(取引成立回数)が減ることで、価格の幅が変動しにくくなるため、ビッド・アスク・スプレッドは小さくなるからである。

さらに、Resiliency が小さくなった理由も同様である。つまり、エージェントの注文価格がファンダメンタル価格周辺に集中することが原因で、1日の値幅も小さくなるため、値幅・出来高比率の分子が小さくなる。分母となる出来高も減少傾向にあるが、分子の減少割合の方が大きいと考えられる。

最後に Depth についてだが、Volume が小さくなる、すなわち、取引成立回数が少ないということは、注文板上の指値注文が多くなることを意味しているため、 $w_{1,max}$  の値が大きいほど Depth は大きくなる。

表 4:  $w_{1,max}$  変更実験

$w_{1,max}$	Volume	Tightness	Resiliency	Depth
1.0	266,285	12.510	0.0107	2,366.39
3.0	246,586	11.971	0.0093	2,832.46
5.0	230,521	11.853	0.0084	3,263.83
8.0	209,168	11.260	0.0075	3,851.76

#### 4.2.4 テクニカル成分の重みの最大値 $w_{2,max}$ 変更実験

テクニカル成分の重みの最大値  $w_{2,max}$  を 3.0, 5.0, 8.0, 10.0 と変化させたときの Volume, Tightness, Resiliency, Depth の平均を表 5 に示す。本実験では 4.2.3 節の実験と同じような結果が得られた。すなわち、 $w_{2,max}$  が大きくなる(テクニカル戦略の比重が大きくなる)と、Volume, Tightness, Resiliency の値は小さくなり、Depth の値は大きくなる。

このようになった理由は、 $w_{1,max}$  のときと本質的に変わらず、ファンダメンタル価格に収束しようとするか市場価格に収束しようとするかの違いだけである。

#### 4.2.5 ばらつき係数 $Est$ 変更実験

エージェントごとの注文価格のばらつきを決めるばらつき係数  $Est$  を 0.003, 0.005, 0.01, 0.02, 0.03 と変化させたときの Volume, Tightness, Resiliency, Depth の平均を表 6 に示す。ばらつき係

表 5:  $w_{2,max}$  変更実験

$w_{2,max}$	Volume	Tightness	Resiliency	Depth
3.0	348,278	32.318	0.0261	632.00
5.0	321,123	21.333	0.0179	1,083.82
8.0	284,556	14.844	0.0126	1,859.86
10.0	266,285	12.510	0.0107	2,366.39

数が大きくなると、Volume, Depth は小さくなり、Tightness, Resiliency は大きくなる。

このようになった理由は Yagi et al.[13] に詳細に記載されているためそちらを参照のこと。

表 6:  $Est$  変更実験

$Est$	Volume	Tightness	Resiliency	Depth
0.003	266,285	12.510	0.0107	2,366.39
0.005	206,633	12.843	0.0124	2,418.61
0.01	131,389	13.581	0.0193	1,811.65
0.02	73,125	14.221	0.0339	1,092.34
0.03	51,040	14.584	0.0494	755.22

#### 4.2.6 注文有効期間 $t_c$ 変更実験

注文有効期間  $t_c$  を 10,000, 15,000, 20,000, 30,000 と変化させたときの Volume, Tightness, Resiliency, Depth の平均を表 7 に示す。

注文有効期間  $t_c$  が大きくなると、Volume, Resiliency は小さくなり、Tightness, Depth は大きくなる傾向が見られた。

このようになった理由については、現在調査中である。

表 7:  $t_c$  変更実験

$t_c$	Volume	Tightness	Resiliency	Depth
10,000	315,304	8.556	0.0222	1,189.10
15,000	267,093	11.535	0.0122	1,972.84
20,000	266,285	12.510	0.0107	2,366.39
30,000	264,833	12.431	0.0098	3,334.00

### 4.3 流動性指標の関係性

表 8 は各パラメータ値を変化させたときの流動性指標変化の結果の一覧である。括弧内の矢印は流動性の変化の方向に記している。

表 8: 各パラメータ値を増加させたときの流動性の変化

パラメータ	Volume	Tightness	Resiliency	Depth
$\Delta P$	減少(↓)	増加(↓)	増加(↓)	増加(↑)
$\sigma_\epsilon$	増加(↑)	増加(↓)	増加(↓)	減少(↓)
$w_{1,max}$	減少(↓)	減少(↑)	減少(↑)	増加(↑)
$w_{2,max}$	減少(↓)	減少(↑)	減少(↑)	増加(↑)
$Est$	減少(↓)	増加(↓)	増加(↓)	減少(↓)
$t_c$	減少(↓)	増加(↓)	減少(↑)	増加(↑)

表 8 からファンダメンタル成分の重みの最大値  $w_{1,max}$ , テクニカル成分の重みの最大値  $w_{2,max}$ , ノイズ成分の予想リターン計算  $e_j^t$  に用いる定数  $\sigma_\epsilon$  において, Volume に基づく流動性とその他 3 つに基づく流動性と正反対であることを示唆している。

いくつかの実証研究 [4][10] では, Volume が増加することにより Depth も上昇することが示されているが, 本研究では Volume は Depth と負の相関を持っている。

この結果の違いは, 本研究でモデル化していないメカニズムにある可能性が示唆された。本研究では, Volume が増加したときに, 多数の指値注文を出すという行動をモデル化していないため, これが Volume と Depth が正の相関を持つメカニズムの 1 つである可能性がある。これは今後の課題である。

ばらつき係数  $Est$  を変化させたときは, Volume に対して, Tightness と Resiliency は負の相関, Depth は正の相関をもつことが分かった。このときは 4 指標全てにおいて流動性の方向性が一致していることが分かる。ばらつき係数  $Est$  の値を変更すると, 取引が成立せずに注文板上に残った指値注文(待機注文)もばらついた状態で残ることになるので, 他のパラメータ値を変化させたときとは異なる動きになると思われる。

ティックサイズ  $\Delta P$  においては, 注文価格を決定する際のティックサイズより小さい端数の処理による人工市場モデルの仕様によるものと考えられる。

#### 4.4 価格の復元速度に基づいた流動性の評価

既述のように, Resiliency は伝統的に値幅・出来高比率が指標として用いられているが, その指標の限界が指摘されている<sup>1</sup>。本来の Resiliency はランダムな価格の振れから実勢価格へ収束する速度で表されるが [10], 実証研究の分野では計測できないため可能な範囲の計測法として致し方なく既存の Resiliency が使用されてきた<sup>2</sup>。

そこで本節では, 市場価格が何かの影響でファンダメンタル価格から大きく乖離したとき, そこからどれだけの期間で市場価格がファンダメンタル価格付近に復元するのかを, 各種パラメータの値を表 2 と同様に変更しながら調査する。今回は 300,001 期から 330,000 期にかけての 30,000 期間, 20% の確

<sup>1</sup>例えば, 1 日を通してみた場合には最高値と最安値の差が小さいと値幅・出来高比率は低めとなる [6]。

<sup>2</sup>既存の計測法では, 1 日中本来戻るべき価格から離れた価格帯で小幅な値動きをする場合などは, 元の価格に全く戻っていないのにも関わらずこの値は小さくなる恐れがある。

率で注文価格 1 の誤発注売り注文を出し, そのときの価格下落率と復元までに必要とする期間を計測する。これらの結果は試行回数 5 回の平均である。市場価格の復元条件は, 市場価格がファンダメンタル価格より 5% 低い水準まで回復すれば復元したものとみなす。

なおこの実験では, 注文価格  $P_{o_j}^t$  は  $P_{o_j}^t - P_d$  から  $P_{o_j}^t + P_d$  までの一様乱数で決め,  $P_d = 1,000$  とした。

#### 4.4.1 計測結果

表 9 は各パラメータ値を変化させたときの価格の復元速度に基づいた指標変化の結果の一覧である。括弧内の矢印は流動性の変化の方向に記している。

表 9: 各パラメータ値を増加させたときの復元速度に基づいた流動性の変化

パラメータ	価格下落率	復元までの期間
$\Delta P$	増加(↓)	減少(↑)
$\sigma_\epsilon$	増加(↓)	減少(↑)
$w_{1,max}$	減少(↑)	減少(↑)
$w_{2,max}$	増加(↓)	増加(↓)
$t_c$	減少(↑)	増加(↓)

以下, 各パラメータの値を変化させたときの価格下落率と復元までの期間について記す。

ティックサイズ  $\Delta P$  を, 0.1, 1.0, 10.0, 100.0 と変化させたときの価格下落率と復元までの期間の平均を表 10 に示す。ティックサイズ  $\Delta P$  が大きくなると, 価格下落率は増加し, 復元までの期間は減少した。ただし,  $\Delta P = 100$  では価格下落率は大きく, 復元までには至らなかった。これは市場価格が 9,900, 9,800 で収束してしまい, 復元条件である 9,950 まで戻らなかったためである。

ティックサイズが大きくなると, 一度の取引での価格の変動が大きくなるため, 価格下落率も大きくなる。下落後のリバウンドの際も, 一度に上昇する値幅が大きくなるため, 復元までの期間も短くなる。

表 10: 4.4 節における  $\Delta P$  変更実験

$\Delta P$	価格下落率 (%)	復元までの期間
0.1	11.33	199,623
1.0	11.17	195,256
10	11.37	186,426
100	11.75	N/A

ノイズ成分の予想リターン計算  $e_j^t$  に用いる定数  $\sigma_\epsilon$  を 0.02, 0.04, 0.06, 0.08, 0.10 と変化させたときの価格下落率と復元までの期間の平均を表 11 に示す。ノイズ成分の予想リターン計算  $e_j^t$  に用いる定数  $\sigma_\epsilon$  が大きくなると, 価格下落率は増加し, 復元までの期間は減少した。

$\sigma_\epsilon$  の値が大きいほど、エージェントの予想価格がばらつく。市場価格の下落とともに注文が出される価格の下限も下がっていくため、価格下落率は大きくなる。下落が終わった後、市場価格の上昇とともに注文が出される価格帯の上限も上がっていく。そのため、復元までの期間は短くなっていく。

表 11: 4.4 節における  $\sigma_\epsilon$  変更実験

$\sigma_\epsilon$	価格下落率 (%)	復元までの期間
0.02	10.92	210,936
0.04	11.20	201,665
0.06	11.17	195,256
0.08	11.82	186,164
0.1	11.99	179,160

ファンダメンタル成分の重みの最大値  $w_{1,max}$  を 1.0, 3.0, 5.0, 8.0 と変化させたときの価格下落率と復元までの期間の平均を表 12 に示す。ファンダメンタル成分の重みの最大値  $w_{1,max}$  が大きくなると、価格下落率と復元までの期間は減少した。

ファンダメンタル成分の重みが大きくなると、予想価格をファンダメンタル価格へ収束させようとする傾向が強くなる。下落しつつもファンダメンタル価格へ収束しようとし、下落が抑えられるため、価格下落率は小さくなる。ファンダメンタル価格へ収束させようとするため、価格の上昇が早くなる。そのため、復元までの期間は短くなる。

表 12: 4.4 節における  $w_{1,max}$  変更実験

$w_{1,max}$	価格下落率 (%)	復元までの期間
1.0	11.17	195,256
3.0	10.01	92,085
5.0	9.38	661,40
8.0	8.27	50,226

テクニカル成分の重みの最大値  $w_{2,max}$  を 3.0, 5.0, 8.0, 10.0 と変化させたときの価格下落率と復元までの期間の平均を表 13 に示す。テクニカル成分の重みの最大値  $w_{2,max}$  が大きくなると、価格下落率と復元までの期間は増加した。

テクニカル成分の重みが大きくなると、予想価格を市場価格へ収束させようとする傾向が強くなる。下落した市場価格に追従していき下落が進むため、価格下落率は大きくなる。市場価格に追従していくため、価格の上昇は遅くなる。そのため、復元までの期間は長くなる。

注文有効期間  $t_c$  を 10,000, 15,000, 20,000, 30,000 と変化させたときの価格下落率と復元までの期間の平均を表 14 に示す。注文有効期間  $t_c$  が大きくなると、価格下落率は減少し、復元までの期間は増加した。

注文有効期間が大きくなると、市場に残る注文の数が増える。市場に残る注文の量が多ければ、最良気配値から大きく離れた価格の注文が取引されず、価格の下落は抑えられるため、価格下落率は小さく

表 13: 4.4 節における  $w_{2,max}$  変更実験

$w_{2,max}$	価格下落率 (%)	復元までの期間
3.0	10.49	91,616
5.0	11.02	123,836
8.0	11.33	169,497
10.0	11.17	195,256

なる。市場に残る注文の量が多ければ、より良い価格で取引が成立しやすく、価格の上昇は緩やかになる。そのため、復元までの期間は長くなる。

表 14: 4.4 節における  $t_c$  変更実験

$t_c$	価格下落率 (%)	復元までの期間
10,000	94.31	42,678
15,000	21.47	115,628
20,000	11.17	195,256
30,000	6.08	260,327

## 5 まとめと今後の課題

流動性の代表的な 4 つの評価軸 (Volume, Tightness, Resiliency, Depth) を計測するための代表的な指標に注目して、それら指標の関係をティックサイズなどの人工市場内のパラメータを変化させることで調査をした。その結果、ノイズ成分の予想リターン計算に用いる定数、ファンダメンタル成分の重みの最大値、テクニカル成分の重みの最大値を変更した場合、Volume に基づく流動性と Tightness と Resiliency, Depth に基づく流動性と正反対であることが分かった。しかし、ばらつき係数を変更した場合、Volume に基づく流動性は、Tightness と Resiliency, Depth に基づく流動性と相関している。これらの結果は本研究では実装されていないメカニズムを追加する必要がある可能性を示唆している。本研究では Volume が高いことを理由に指値注文を増やすという行動をモデル化していないため、これが Volume と Depth が正の相関をもつメカニズムである可能性がある。このメカニズムについて検証する必要がある。

一方で、注文有効期間  $t_c$  を変化させた場合にはほかの 5 つのパラメータとは違った相関をもった。このメカニズムの解明も今後の課題である。

また、実証研究では計測できない実勢価格へ収束する速度に関しても、価格下落率と復元までの期間を人工市場内のパラメータを変化させることで調査をした。その結果、ノイズ成分の予想リターン計算に用いる定数を変更した場合、パラメータの増加に対し、価格下落率は正の相関、復元までの期間は負の相関を持った。ファンダメンタル成分の重みの最大値、テクニカル成分の重みの最大値を変更した場合、両者は正反対の相関を持った。注文有効期間  $t_c$

を変化させた場合には、価格下落率は負の相関、復元までの期間は正の相関を持った。

## 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す。

## 参考文献

- [1] Yakov Amihud. : Illiquidity and stock returns: Cross-section and timeseries effects, *Journal of Financial Markets*, pp.31–56, 2002.
- [2] S.-H. Chen, C.-L. Chang, and Y.-R. Du. : Agent-based Economic Models and Econometrics, *Knowledge Engineering Review*, Vol.27, No.2, pp. 187–219, 2012.
- [3] C. Chiarella, G. Iori, and J. Perello. : The Impact of Heterogeneous Trading Rules on the Limit Order Flows, *Journal of Economic Dynamics and Control*, Vol.33, No.3, pp. 525–537, 2009.
- [4] K. H. Chung, K. A. Kim, and P. Kitsabunarat : Liquidity and quote clustering in a market with multiple tick sizes, *Journal of Financial Research*, Vol. 28, No. 2, pp. 177–195, 2005.
- [5] R. Cont. : Empirical properties of asset returns: stylized facts and statistical issues, *Quantitative Finance*, Vol. 1, pp. 223–236, 2001.
- [6] T. Kurosaki, Y. Kumano, K. Okabe, and T. Nagano. : Liquidity in JGB Markets: An Evaluation from Transaction Data, *Bank of Japan Working Paper Series 15-E-2*, Bank of Japan, May 2015.
- [7] Albert S. Kyle. : Continuous auctions and insider trading, *Econometrica*, Vol.53, pp. 1315–1336, 1985.
- [8] T. Mizuta, K. Izumi, I. Yagi, and S. Yoshimura. : Regulations’ effectiveness for market turbulence by large erroneous orders using multi agent simulation. In *Computational Intelligence for Financial Engineering Economics (CIFEr)*, 2014 IEEE Symposium Series on Computational Intelligence on, pp. 138–143, March 2014.
- [9] T. Mizuta, K. Izumi, I. Yagi, and S. Yoshimura. : 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.
- [10] J. Muranaga. : Dynamics of market liquidity of japanese stocks: An analysis of tick-by-tick data of the tokyo stock exchange, In *Bank for International Settlements*, editor, *Market Liquidity: Research Findings and Selected Policy Implications*, Vol. 11, pp. 1–25. Bank for International Settlements, 1999.
- [11] K. Nishizaki, A. Tsuchikawa, and T. Yagi. : Indicators related to liquidity in jgb markets, *Bank of Japan Review Series 13-E-3*, Bank of Japan, 2013.
- [12] M. Sewell. : Characterization of financial time series, 2006.
- [13] I. Yagi, Y. Masuda, and T. Mizuta. : Detection of Factors Influencing Market Liquidity Using an Agent-based Simulation, *The 5th International Conference on Behavioral, Economic, and Socio-Cultural Computing (BESC2018)*, November 2018.
- [14] I. Yagi, A. Nozaki, and T. Mizuta. : Investigation of the rule for investment diversification at the time of a market crash using an artificial market simulation, *Evolutionary and Institutional Economics Review*, Vol. 14, No. 2, pp. 451–465, 2017.
- [15] R. Yamamoto and H. Hirata. : Strategy switching in the japanese stock market, *Journal of Economic Dynamics and Control*, Vol. 37, No. 10, pp. 2010–2022, 2013.
- [16] Bank for International Settlements : Recommendations for the design of liquid markets, Bank for International Settlements, 1999.

# シミュレーションによるインデックス投資の市場価格形成への影響分析

松浦 出<sup>\*1</sup>      和泉 潔<sup>\*1</sup>      坂地 泰紀<sup>\*1</sup>      松島 裕康<sup>\*1</sup>      島田 尚<sup>\*1</sup>  
Izuru Matsuura      Kiyoshi Izumi      Hiroki Sakaji      Hiroyasu Matsushima      Takashi Shimada

<sup>\*1</sup>東京大学 大学院工学系研究科  
School of Engineering, the University of Tokyo

In this paper, we modeled stock markets to investigate the effect of index investing on stock price formation. We showed that index investing has little effect on stock price formation in our stock markets model by analyzing results from experiments with various market settings.

## 1. はじめに

インデックス投資とよばれる投資法がある。投資する資産を、すべての株式に、その時価総額の比で按分して投資するというものである。[Sharpe 64]に始まる一連の研究を理論的背景に持つこの投資法により運用される資産は、現在では投資信託の総運用資産の無視できない割合を占めるに至っている。

インデックス投資では、企業の業績を全く勘案せずに投資が行われる。そのためインデックス投資があまりに大きなシェアを占めた場合、証券市場での価格形成が適正に行われず、有望な企業に資金が集まらない、あるいは投資に値しない企業に資金が集まってしまう可能性が考えられる。

本論文では、インデックス投資が本当にこのような価格形成の問題を引き起こすのか、また引き起こすとすれば、それはどの程度価格形成に影響を与えるのかを検証した。具体的には、証券市場に存在する証券と市場参加者、および価格決定をモデルとして設計し、いくつかのパラメータについてのシミュレーション実験を通して影響を分析した。

## 2. 証券市場のモデル

本節では、本研究で扱う証券市場のモデルについて述べる。

証券市場には  $m$  種類の証券が存在し、その 1 株あたりのペイオフ  $\theta = (\theta_1, \theta_2, \dots, \theta_m)^T$  は、平均  $\bar{\theta}$ 、共分散行列  $\Sigma$  の正規分布  $\mathcal{N}(\bar{\theta}, \Sigma)$  に従う。また無リスク資産が存在し、その利率は 0 である。時間  $t = 0$  で、すべての証券が 1 単位だけ供給される。

証券市場には  $n$  社のファンドが参加している。うち  $n-1$  社がインデックス投資を行わないファンド（以下ではアクティブファンドと呼ぶ）であり、1 社がインデックス投資を行うファンド（以下インデックスファンドと呼ぶ）である。

すべてのファンドは時間  $t = 0$  で投資し、 $t = 1$  に回収する。回収までにポートフォリオを組み替えることはできない。

$n-1$  社のアクティブファンドはすべて絶対的リスク回避度一定型の効用関数を持つ。 $j$  番目のアクティブファンドは  $t = 0$  で  $\theta$  に関するシグナル  $s_j = \theta + \varepsilon_j + \eta$  を受けとる。ここで、 $\theta$  は次期の証券のペイオフ、 $\varepsilon_j$  はファンドに固有の誤差、 $\eta$  はすべてのファンドに共通して入りこむ誤差を表し、 $\varepsilon_j \sim \mathcal{N}(0, \Sigma_\varepsilon)$ 、 $\eta \sim \mathcal{N}(0, \Sigma_\eta)$ 、 $(\Sigma_\varepsilon = \sigma_\varepsilon^2 \Sigma, \Sigma_\eta = \sigma_\eta^2 \Sigma)$  を仮定する。アクティブファンドは受けとったシグナルをもとに、自身の期待効用を最大化するよう行動する。

ただ 1 社存在するインデックスファンドは各証券の時価総額に応じて投資する。インデックスファンドの証券  $k$  への投

資額は、証券  $k$  の時価総額がすべての証券の時価総額の和に占める割合に、運用総資産を掛けた額である。

### 2.1 アクティブファンドの行動

各アクティブファンドは、自身の期待効用を最大化するよう投資する。アクティブファンドの効用関数には絶対的リスク回避度一定型を仮定する。すなわち  $j$  番目のアクティブファンドの効用関数  $u_j(x)$  は、 $t = 1$  での運用資産  $y$  に対して、

$$u_j(y) = -e^{-\rho y} \quad (1)$$

と表せる。 $\rho > 0$  は絶対的リスク回避度である。 $\rho$  はすべてのアクティブファンドに共通であると仮定する。

この状況では、シグナル  $s_j$  を得たアクティブファンド  $j$  の投資  $x_j$  は次の最適化問題の解である。

$$\text{maximize } E \left[ u_j \left( \theta^T x_j \right) \middle| s_j \right] \quad (2)$$

$$\text{subject to } p^T x_j = b_j \quad (3)$$

ただし  $\theta'$  は  $m$  種類の証券に無リスク資産を加えた  $\theta' = (1, \theta_1, \dots, \theta_m)^T$  のことであり、 $p$  は  $t = 0$  での無リスク資産を含む証券の市場価格ベクトル  $p = (1, p_1, \dots, p_m)^T$ 、 $b_j$  はアクティブファンド  $j$  の運用資産である。

実はこの最適化問題は次の問題と等価である。<sup>\*1</sup>

$$\text{maximize } \theta_j^T x - \frac{\rho}{2} x^T \Sigma_j x \quad (4)$$

$$\text{subject to } p^T x_j = b_j \quad (5)$$

$\theta_j$ 、 $\Sigma_j$  はそれぞれ  $s_j$  を所与とした  $\theta'$ 、 $\Sigma'$  の条件付き平均、条件付き分散である。この解は方程式、

$$\begin{pmatrix} \rho \Sigma_j & p \\ p^T & 0 \end{pmatrix} \begin{pmatrix} x_j \\ \lambda \end{pmatrix} = \begin{pmatrix} \theta_j \\ b_j \end{pmatrix} \quad (6)$$

を解くことで得られる。

### 2.2 インデックスファンドの行動

インデックスファンドはマーケットポートフォリオに投資する。すなわち、証券価格  $p = (p_1, \dots, p_m)^T$  と運用資産  $b$  に対して、各証券に  $b(p_1, \dots, p_m)^T / \sum_i p_i$  だけ投資する<sup>\*2</sup>。

<sup>\*1</sup> 証明は付録参照

<sup>\*2</sup> すべての証券の供給を 1 に正規化しているので、時価総額は価格と等しい。そのため時価総額の比が  $(p_1, \dots, p_m)^T / \sum_i p_i$  となる

## 2.3 価格の決定方法

証券の価格は、すべての証券の超過需要が0となる価格で決定される。<sup>\*3</sup> 価格  $p \in \mathbb{R}^m$  における証券の超過需要  $D(p) \in \mathbb{R}^m$  とは、 $D_j(p) \in \mathbb{R}^m$  を、価格が  $p$  であるときの第  $j$  ファンドの需要として、次の式で定義される量である。

$$D(p) = \sum_{j=1}^n D_j(p) - 1 \quad (7)$$

超過需要を0とする  $p$  は、 $p$  についての方程式  $D(p) = 0$  をニュートン法で解くことで得られる。

## 2.4 各証券がどの程度正確に価格付けられているかの指標

インデックスファンドが存在せず、アクティブファンドが受け取るシグナルが、 $\theta + \eta$  であるとき、つまり  $\sigma_\varepsilon = 0$  の場合を、最も正確な情報が反映された市場と考える。この市場で実現する価格  $p_f$  を完全情報価格と呼ぶことにし、これをベンチマークとする。ある市場がどの程度情報を反映しているかを、その市場で実現する価格  $p_p$  が完全情報価格からどの程度離れているか表す指標

$$d(p_p) = \frac{\|p_p - p_f\|}{\|p_f\|} \quad (8)$$

により評価する。以下ではこの指標を完全情報価格からの乖離度と呼ぶ。

## 3. シミュレーション実験による検証

### 3.1 パラメータの決定法

本モデルでは、証券市場はファンドの数  $n$ 、証券の種類  $m$ 、ペイオフの期待値  $\bar{\theta}$  と共分散行列  $\Sigma$ 、アクティブファンドの絶対的リスク回避度  $\rho$ 、ファンドに固有の誤差の大きさ  $\sigma_\varepsilon$ 、共通の誤差の大きさ  $\sigma_\eta$  のパラメータで決定される。証券に関するパラメータ  $m, \bar{\theta}, \Sigma$  は、東証第1部の1業種を1つの証券と対応させて、2010年1月から2018年9月までの業種別時価総額の月次データから定める。2010年1月から2018年9月までの業種毎の時価総額の月次成長率  $\mu$  とその共分散行列  $\Sigma_\mu$  をモーメント法により推定する。2018年9月の業種  $i \in \{1, 2, \dots, 33\}$  の時価総額  $S_i$  を、すべての業種の時価総額の和  $\sum_{i=1}^{33} S_i$  で割ったものを  $s_i$  とし、 $s = (s_1, \dots, s_{33})^T$  とする。これらの値を用いて、 $\bar{\theta} = \mu * s$ 、 $\Sigma = (s s^T) * \Sigma_\mu$  (ただし  $*$  は要素ごとの積) とする。

$\rho$  の値に応じて投資行動がどのように変化するかを見るために、簡単な例を挙げる。確率0.8で賭け金が2倍に、確率0.2で0になるギャンブルを考える。パラメータ  $\rho$  の絶対的リスク回避度一定型効用を持つ人が資産  $b$  のうち  $w$  だけをこのギャンブルに回すとする。彼のギャンブルへの投資額  $w$  は、 $X$  を成功確率0.8のベルヌーイ分布に従う確率変数として、

$$\mathbb{E} \left[ -e^{-\rho(1-w+2wX)} \right] \quad (9)$$

を最大化するよう決定される。この関数を最大化する  $w$  は、

$$w = \frac{15}{16\rho} \quad (10)$$

\*3 この価格決定モデルは経済学で一般均衡理論として知られるものである。詳細は [Jean- Pierre 07]1 章などを参照。

である。絶対的リスク回避度一定型の効用関数を持つ人は、その資産の多寡にかかわらずギャンブルへの投資額を決める。<sup>\*4</sup>  $\rho = 1$  であれば15/16を、 $\rho = 15$  であれば1/16を、 $\rho = 150$  であれば1/160をギャンブルに回すわけである。実験の詳細の節で詳述する通り、本実験では各アクティブファンドの運用資産は1/160から1/16程度である。前述のギャンブルのような有利な投資案への投資額がこのようなものであることを考えると、絶対的リスク回避度  $\rho$  は1から64程度に設定するのがよいだろう。

アクティブファンドの推定誤差の大きさ  $\sigma_\varepsilon, \sigma_\eta$  については、どのような値が適切であるか見当がつかないため、 $(\sigma_\varepsilon, \sigma_\eta) \in \{1, 2, 4, 8, \dots, 64\}^2$  のすべての場合について調べ上げる。

$\sigma_\varepsilon, \sigma_\eta$  の値について、もう少し詳しく解釈しておく。まずシグナル  $s_j = \theta + \varepsilon_j + \eta$  のもとでの  $\theta$  の条件付き期待値と分散は、

$$\mathbb{E}[\theta|s_j] = \bar{\theta} + \Sigma(\Sigma + \Sigma_\varepsilon + \Sigma_\eta)^{-1}(s_j - \bar{\theta}) \quad (11)$$

$$= \frac{\sigma_\varepsilon^2 + \sigma_\eta^2}{1 + \sigma_\varepsilon^2 + \sigma_\eta^2} \bar{\theta} + \frac{1}{1 + \sigma_\varepsilon^2 + \sigma_\eta^2} s_j \quad (12)$$

$$\text{Var}[\theta|s_j] = \Sigma - \Sigma(\Sigma + \Sigma_\varepsilon + \Sigma_\eta)^{-1}\Sigma \quad (13)$$

$$= \frac{\sigma_\varepsilon^2 + \sigma_\eta^2}{1 + \sigma_\varepsilon^2 + \sigma_\eta^2} \Sigma \quad (14)$$

である。各アクティブファンドの受け取るシグナルがどの程度信頼できるかは  $\sigma_\varepsilon^2 + \sigma_\eta^2$  のみによって決定される。 $\sigma_\varepsilon^2 + \sigma_\eta^2$  が小さければ小さいほど、ファンドは自身が受け取ったシグナルをより信頼する。 $\sigma_\varepsilon^2$  と  $\sigma_\eta^2$  個別の値は、ファンド間のシグナルがどの程度ばらつくかにも影響する。

### 3.2 実験の詳細

インデックスファンドの運用資産が市場に占める割合と、完全情報価格からの乖離度の関係を調べるために、次のような実験を行った。 $m, \bar{\theta}, \Sigma$  はすべての実験で前述の、東証1部の業種別時価総額から定めた値を使う。またファンドの数は  $n = 16$  を採用する。各実験では、パラメータ  $\rho, \sigma_\varepsilon, \sigma_\eta$  の値を1つ選んだ。インデックスファンドの運用資産  $C_i$  を決定し、アクティブファンドの運用資産を  $(1 - C_i)/(n - 1)$  で定めた。シード値を1から20まで変化させ、それぞれのシード値について、この市場で実現する価格  $p_p$  を計算し、同じシード値を用いて完全情報価格  $p_f$  を計算した。結果として得られた  $p_p$  の  $p_f$  からの乖離度  $d(p_p)$  と、 $C_i$  の値との関係性を評価した。

### 3.3 結果と考察

図1は、 $\rho = 16$  を固定して、 $\sigma_\varepsilon, \sigma_\eta$  ごとに横軸に  $C_i$  を、縦軸に  $d(p_p)$  をプロットしたものである。インデックスファンドの運用資産  $C_i$  の大きさにかかわらず、完全情報価格からの乖離度はほぼ一定のようである。 $C_i$  が大きくなるにつれて完全情報価格からの乖離度が線形に増加する傾向があるようには見えないが、この原因はおそらく次のようなものである。

本実験ではアクティブファンドの効用関数に絶対的リスク回避度一定型を仮定したので、アクティブファンドの運用資産の額によらず、アクティブファンドがリスク資産に投資する額は一定である。一方インデックスファンドは運用資産のすべてを

\*4 ファンドの効用関数に絶対的リスク回避度一定型を仮定すると、ファンドの運用資産の規模によってその性質が大きく変わってしまう。ファンドが投資家にある一定の性質を持つ金融商品を提供するものであると考えると、この特徴を持つ効用関数を採用するのはあまり適切ではない。当該仮定は計算時間を削減するための技術的なものである。

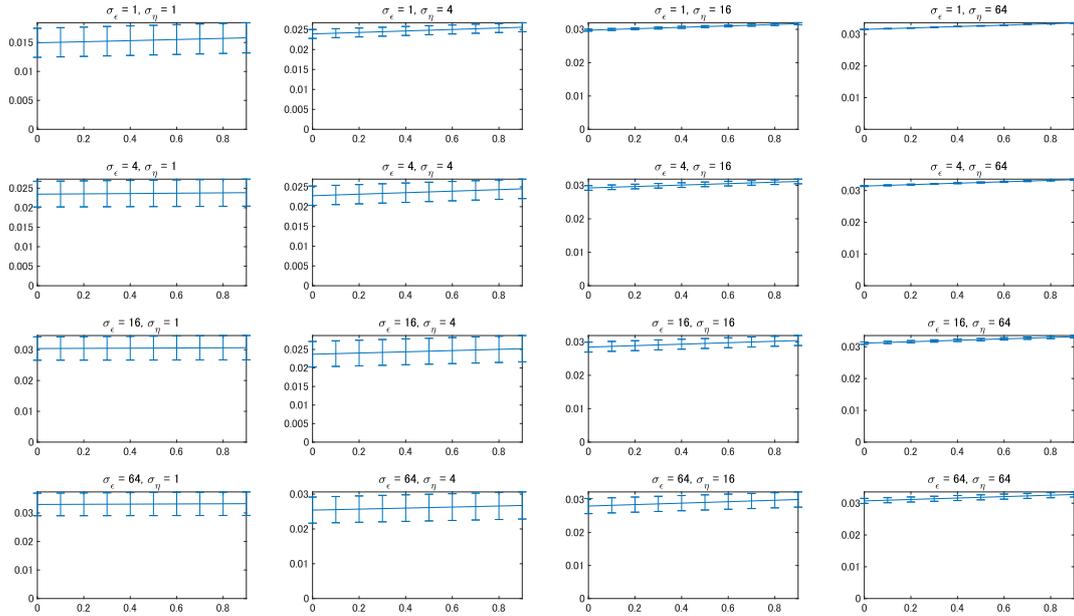


図 1:  $\sigma_\epsilon^2, \sigma_\eta^2$  ごとの、インデックスファンドのシェア（横軸）と完全情報価格からの乖離度（縦軸）との関係

リスク資産に投資するので、 $C_i$  の値に応じて市場全体でのリスク資産への投資額が線形に増加する。リスク資産に投資された額が大きいほど各リスク資産の価格は上昇して、 $C_i = 0$  の状況で計算された完全情報価格から乖離するはずである。

$\rho$  の値を  $\rho = 1, 2, 4, 8, 16, 32, 64$  と変化させて同一の分析をしたところ、 $\rho = 16$  のときと同じく、 $C_i$  と  $d(p_p)$  の間には非常に小さな線形の関係が見られた。

以上のことから、本論文で設定したモデル上では、インデックスファンドが市場の価格形成に与える影響はほとんどないと言えるだろう。

本実験の結果は、本質的に次の 2 つの仮定によるものであると考えられる。

- アクティブファンドのシグナルの正確さ、つまり  $\sigma_\epsilon^2$  の小ささが、ファンドの運用資産に依存せず一定であると仮定したこと
- アクティブファンドの効用関数に絶対的リスク回避度一定型を仮定したこと。

この 2 点を考慮すると結果が大きく変わりうる。インデックスファンドのシェアが大きくなったとき、前者はアクティブファンドの運用資産の減少によって、分析に使える資源が減り、受け取るシグナルが正確でなくなることを通じて、後者は正確な情報を持ったアクティブファンドがリスク資産への投資額を減少させることを通じて、市場価格と完全情報価格との乖離を大きくすると考えられる。

前者を考慮するには、 $\sigma_\epsilon^2$  をアクティブファンドの総資産の大きさに反比例するように定めればよい。

後者を考慮するには、アクティブファンドの効用関数に相対的リスク回避度一定型効用関数を仮定すればよい。相対的リスク回避度一定型の効用関数を持つアクティブファンドの意思決定は、本モデルの絶対的リスク回避度一定型効用関数を持つア

クティブファンドの意思決定に比べて、計算資源を要すると考えられる。

当面の課題はこの 2 つの仮定を緩和したモデルの作成と実装である。

#### 4. まとめ

インデックス投資が証券市場の価格形成に与える影響を見るために、証券市場のモデルを作成した。またそのモデル上での実験結果から、インデックス投資が価格形成にほとんど影響を与えていないことを示した。

今後はアクティブファンドの効用関数を相対的リスク回避度一定型に差し替え、またアクティブファンドの予測能力が運用資産に依存する構造をモデルに導入し、市場への影響の変化を分析したい。

#### 参考文献

[Jean- Pierre 07] Jean- Pierre Danthine, Donaldson, J. B.: 現代ファイナンス分析 資産価格理論、ときわ総合サービス (2007)

[Sharpe 64] Sharpe, W. F.: Capital asset prices: A theory of market equilibrium under conditions of risk, *The journal of finance*, Vol. 19, No. 3, pp. 425-442 (1964)

#### A 付録

##### A1 最適化問題 (2) と最適化問題 (4) の等価性

最適化問題 (2) は、問題 (4) と等価である。これは次のようにして示せる。

$Z = \theta^T x_j$  とし、 $Z$  の  $s_j$  の条件付き密度関数を  $f_{Z|s_j}(z|s_j)$

とすると,

$$E \left[ u_j \left( \theta'^T x_j \right) \middle| s_j \right] = E \left[ -\exp(-\rho Z) \middle| s_j \right] \quad (15)$$

$$= - \int e^{-\rho z} f_{Z|s_j}(z|s_j) dz \quad (16)$$

である. ここで,  $\theta', s_j$  の両方が正規分布に従うことから,  $s_j$  のもとでの  $\theta'$  の条件付き分布は正規分布である. したがって, その期待値を  $\theta_j$ , 分散を  $\Sigma_j$  とすると,  $Z = \theta'^T x_j$  の  $s_j$  のもとでの条件付き分布は, 期待値  $\bar{z} = \theta_j^T x_j$ , 分散  $\sigma^2 = x_j^T \Sigma_j x_j$  の正規分布である. これを用いると,

$$\begin{aligned} & - \int e^{-\rho z} f_{Z|s_j}(z|s_j) dz \\ &= - \int e^{-\rho z} \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(z-\bar{z})^2}{2\sigma^2}\right) dz \\ &= \int \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(z-\bar{z}+\rho\sigma^2)^2}{2\sigma^2}\right) dz \\ & \quad \times \left(-\exp\left(-\rho\bar{z} + \frac{\rho^2}{2}\sigma^2\right)\right) \end{aligned}$$

が得られる. この式の最右辺の被積分関数は, 期待値  $\bar{z} - \rho\sigma^2$ , 分散  $\sigma^2$  の正規分布の密度関数であるからその積分値は 1 である. ゆえに式 (2) は  $-\exp\left(-\rho\bar{z} + \frac{\rho^2}{2}\sigma^2\right)$  と等しい.

以上により式 (2) の最大化は,  $-\exp\left(-\rho\bar{z} + \frac{\rho^2}{2}\sigma^2\right)$  の最大化に帰着することがわかった. さらにすべての  $x_j$  と  $x'_j$  に対して,

$$-\exp\left(-\rho\bar{z} + \frac{\rho^2}{2}\sigma^2\right) > -\exp\left(-\rho\bar{z}' + \frac{\rho^2}{2}\sigma'^2\right) \quad (17)$$

$$\Leftrightarrow \exp\left(-\rho\bar{z} + \frac{\rho^2}{2}\sigma^2\right) < \exp\left(-\rho\bar{z}' + \frac{\rho^2}{2}\sigma'^2\right) \quad (18)$$

$$\Leftrightarrow -\rho\bar{z} + \frac{\rho^2}{2}\sigma^2 < -\rho\bar{z}' + \frac{\rho^2}{2}\sigma'^2 \quad (19)$$

$$\Leftrightarrow \bar{z} - \frac{\rho}{2}\sigma^2 > \bar{z}' - \frac{\rho}{2}\sigma'^2 \quad (20)$$

$$\Leftrightarrow \theta_j^T x_j - \frac{\rho}{2} x_j^T \Sigma_j x_j > \theta_j^T x'_j - \frac{\rho}{2} x_j'^T \Sigma_j x'_j \quad (21)$$

であるから, 最適化問題 (2) は別の最適化問題 (4) に帰着する.

# Verification for Liquidity of Real Estate Assets via Artificial Market Approach

曹 治平\*1 水田孝信\*2

Zhiping Cao Takanobu Mizuta

1 東京工業大学 環境・社会理工学院 技術経営専門職学位課程

Tokyo Institute of Technology

2 スパークス・アセット・マネジメント株式会社

SPARX Asset Management Co., Ltd.

**Abstract:** Asset Management Industry may experience a drastic change. The added value of the industry might be lower due to the improvement of technology (Fintech), Fiduciary duty and passive trend. Under such situation, the differentiation of traditional investment will be more and more difficult, and investor will favor alternative products. However, Asset Management companies face the big hurdle in providing alternative products to individual investors due to the Liquidity. Japan regulator tend to restrict the illiquidity assets from the perspective of investor protection. This study will focus on the Real Estate, one of the major alternative products. Real Estate itself is illiquidity asset, while equity Real Estate Investment Trusts (REIT), one of the Real Estate investment products, is liquidity asset and every investor can trade it every day, every time as equity. And regulator tend to restrict other less liquidity Real Estate investment products from the perspective of investor protection as many investors had painful experience in 90s.

There were many empirical researches for the liquidity issue of equity REIT. However, all there are using the historical data, and it is difficult the analysis without the market environmental change.

This study uses a financial market simulation (artificial market) constructed virtually on computer to assess the relationship between liquidity and market price. Artificial market method has been using for short selling rule and other regulation rule in Japan, but no trade frequency simulation has been conducted before.

Analysis results showed that

1. High liquidity might heighten the volatility of the marketable securities. And it will case the price divergence between market price and original value.
2. Fundamental investors and Technical investors should have the same trade frequency.
3. For real estate assets, due to the information disclosure frequency, the trade frequency which can make market efficiency might be once per monthly.

## 1. はじめに

近年インフレ率の低下、国債の低金利などによって、投資家は株式、債券などの伝統的資産において利益を獲得することが難しくなっており、不動産投資、インフラ投資、ヘッジファンド投資などに代表されるオルタナティブ資産に積極的に投資するようになった。機関投資家のみでなく、個人による小口少額の不動産投資に対するニーズも高まるようになってきており、ファンド型不動産投資が注目を集めている。

ファンド型不動産投資には REIT という形態の商品があるものの、株式ようにいつでも取引できるため、株式市場全体の影響(ベータ)を受けやすく、不動産本来の安定した値動きの特性を受けにくい傾向がある。

市場環境変化などその他の要因を排除するため、実証研究は難しいことから、本研究では、流動性のうち取引できる頻度フォーカスして、人工市場でシミュレーションを行い、取引頻度と価格の関係を検証する。

人工市場は、金融市場の分析手法の一つで、コンピューター上に仮想的に構築した金融市場マルチエージェントシステムである。エージェントにそれぞれ独自の売買手法を与え、それらに投資家として金融資産の取引をさせ、市場がどのようなふるまいをするかを確認することができる [1]。

しかし、これまでに人工市場を用いた取引頻度を制限した研究はなかった[2][3]。

そこで、本研究では、取引の頻度を制限した人工市場モデルを構築し、取引頻度と市場効率性の関係を調べた。

## 2. 手法—人工市場モデル

本研究では取引頻度の制限に最適なモデルを独自で構築する。本研究においては、上場 REIT(Equity REIT)を

想定したリスク資産 1 つのみを売買対象とする。また、取引頻度によって、市場価格がどの程度資産(不動産)の本来の価値である価額から乖離するかを目的とするため、取引価格の決定に重きを置く。そのため、取引価格と頻度のみの関係を観測できるように、取引数量などその他の要因はできるだけ排除したモデルを構築している。具体的には、後述(2.2)の各市場参加者(エージェント)の初期の保有資産を 1 株もしくは初期株価に該当する金額に設定し、エージェントは、1 株保有者は売り、保有なしは買いの売買行動を取るとする。その結果、2 株以上の保有、および空売りは発生しないことになる。不動産の価格は、景気の変動の影響を受けるため、周期性の特性を持つ。[4]したがって本研究において、比較対象である不動産の本来価値については、 $n$  期を周期とし、平均  $a$ 、振幅  $A$  の  $\sin$  を外部から与えるとする。 $t$  期の本来価値 True Value は以下のように表現される。

$$TrueValue_t = a + A \sin 2\pi \frac{t}{n}$$

以下、本モデルにおける取引価格決定モデルと、本モデルに参加する各エージェントについて述べる。

### 2.1. 価格決定モデル

各エージェントは 2.2 で述べるそれぞれの手法を用いて発注価格を決定し、注文を出す。前述の通り、売買は株数を保有しているかどうかで決まる。市場では、第  $t$  期のすべてのエージェントの買い注文と売り注文を突き合わせて売買を成立させる。板寄せモデルを使用する。買い注文者は高い注文価格を発注したエージェントから、売り注文者は安い注文価格を発注したエージェントから、優先的に市場取引に参加し、買い手価格が売り手価格を上回るもしくは一致するときのみ売買が成立する。

## 2.2. エージェント

取引に参加するエージェントのタイプは、ファンダメンタルエージェント、テクニカルエージェント、ノイズエージェントの3種類である。実際の市場においては、ファンダメンタルエージェントは機関投資家および外国人投資家の一部、テクニカルエージェントは個人投資家および外国人投資家の一部、ノイズエージェントは一般的な金融市場と同様な流動性を得るために設定している。エージェントの種類は人口市場に関する先行研究で比較的に使われているものになっている。[5]

### 2.2.1. ファンダメンタルエージェント

本研究におけるファンダメンタルエージェントは資産の本来価値をある程度想定でき、かつその想定した価値をもとに取引を行う投資家とする。つまり、各エージェントは本来価値 True Value から少しだけずれた価格を独自の本来価値として認識し、買い手はその独自の本来価値よりもリスク許容度分だけ安い値段で買い注文を、売り手はその独自の本来価値よりもリスク許容度分だけ高い値段で売り注文をそれぞれ発注する。本来価値からのずれ、およびリスク許容度はエージェント毎、期毎に異なる。本来価値からのずれは標準分布乱数に従い、リスク許容度は一様な乱数に従う。t期のファンダメンタルエージェントの発注価格 $Pf_t$ は以下の式で表現される。

$$Pf_t = TrueValue_t \times d\sigma_j \pm r(1 + \mu_j)$$

d: 本来価値からのずれの最大値

$\sigma_j$ : 正規分布乱数

r: リスク許容度の最大値  $\mu_j$ : 0~1 の一様乱数

±: 買い手“-”、売り手“+”

### 2.2.2. テクニカルエージェント

本研究におけるテクニカルエージェントは過去の取引価格のトレンドのみに基づいた売買行動を行う。したがって、テクニカルエージェントは本来価値を考慮することはない。テクニカルエージェントは順張りとは逆張りの2種類存在する。以下それぞれの売買行動について説明する。

#### 2.2.2.1. 順張りテクニカルエージェント

順張りテクニカルエージェントは、過去の取引価格のトレンドが続くと予想するエージェントである。つまり、過去の取引価格が上がると、今後も上がると予想し、下がると、今後も下がると予想する。また過去の取引価格を参照する期間はエージェント毎に異なり、一様乱数で参照期間が決定される。なお、テクニカルエージェントの価格の予想の個人差を表現するために、さらに予想された価格にずれを取り入れる。ずれは標準分布乱数に従う。t期の順張りテクニカルエージェントの発注価格 $Pt_t$ は以下の式で表現される。

$$Pt_t = P_{t-1} \times \frac{P_{t-1}}{P_{t-m}} \times l\sigma_j$$

l: テクニカルエージェントのずれの最大値

$\sigma_j$ : 正規分布乱数

m: 0~最大参照期間の一様乱数

$P_t$ : t期の取引価格

#### 2.2.2.2. 逆張りテクニカルエージェント

逆張りテクニカルエージェントは、順張りテクニカルエージェントとは逆で、過去の取引価格に対して懐疑的なエージェントである。過去の取引価格が上がると、今後は下がると予想し、下がると、今後は上がると予想する。また、順張りテクニカルエージェント同様、過去の取引価格の参照期間はエージェント毎に異なり、一様乱数で決定される。かつ、標準分布乱数に従い、ずれも発生する。t期の逆張りテクニカルエージェントの発注価格 $Pt'_t$ は以下の式で表現される。

$$Pt'_t = P_{t-m} \times l\sigma_j$$

l: テクニカルエージェントのずれの最大値

$\sigma_j$ : 正規分布乱数

m: 0~最大参照期間の一様乱数

$P_t$ : t期の取引価格

### 2.2.3. ノイズエージェント

ノイズエージェントは本研究の人工市場に対して流動性を提供するために設定している。1期前の取引価格に対して、一定の幅を元に正規分布乱数に基づいて発注価

格を決定する。t 期の発注価格  $Pn_t$  は以下の数式で表現される。

$$Pn_t = P_{t-1} \times S\sigma_j$$

S: 発注価格の分布の幅

$\sigma_j$ : 正規分布乱数

$P_t$ : t 期の取引価格

### 2.3. 取引頻度の制限

本研究では情報伝達および判断の差を取引頻度として表現し、取引頻度の制限を表 1 の通り、3 パターンで分析を行う。

シナリオ	取引制限		
	ファンダメンタルエージェント	テクニカルエージェント	ノイズエージェント
1(自由シナリオ)	制限なし	制限なし	制限なし
2(現実シナリオ)	制限あり	制限なし	制限なし
3(制限シナリオ)	制限あり	制限あり	制限なし

表 1 取引制限の種類

シナリオ 1 はすべての市場参加者が同じタイムスパンで情報を取得でき、最適な取引価格を分析し、発注を行う理想的な市場である。このような市場は効率的で、本来価値と取引価格にずれが生じても、乖離は修正されると考えられる。

一方、現実的な取引制限のない市場では、ファンダメンタルエージェントが発注価格を決定するにあたって必要とする情報と時間は、過去の取引価格のみで発注価格を決定するテクニカルエージェントよりも大幅に多いと考えられる。さらに、この傾向は HFT によって、テクニカルエージェントの意思決定の短縮化により、強くなった可能性がある [6] [7][8][9]。したがって、本研究では、表 1 の制限シナリオ 2 のようにファンダメンタルエージェントの取引頻度を制限することで、このような市場を表現する。

また、本研究目的である、テクニカルエージェントの取引頻度を規制などによって意図的に制限することで、取引価格に与える影響を調査するために、制限シナリオ 3 という現実ではない市場を構築する。制限シナリオ 3 は仮にファンダメンタルエージェントの意思決定速度に合わせて市場全体の取引頻度を制限した場合、取引価格と本来価値の乖離に与える影響を調べている。なお、制

限シナリオ 3 においては、時間軸の表現を行うために、あえてノイズエージェントの取引を制限していない。

## 3. シミュレーション

本研究では、本来価値の  $\sin$  の周期を 500 期とし、3000 期(6 周期)のシミュレーションを行う。また、シミュレーションを行う際に用いる変数を、エージェントの比率の説明と、その他の変数に分けて説明する。乱数をパラメーターに導入しているため、各種シミュレーションは全て 20 回以上行う。

### 3.1. エージェントの比率

人工市場モデルにおいて、ファンダメンタルエージェントの数とテクニカルエージェントの数バランスによって、結果が変わることは先行研究で証明されている [2][10]。本研究では、できるだけ現実の市場に近い比率でファンダメンタルエージェントとテクニカルエージェントの数を決定する。東証 REIT の売買取引参加者状況のデータがないため、ここでは東証 1 部の売買取引参加者状況を代替に使う。東京証券取引所が週次単位で発表している「投資部門別売買状況」を利用する。

本研究では「投資部門別売買状況」を参照し、エージェントの数を以下表 2 の通りに設定する。

エージェントタイプ	個数	比率
ファンダメンタルエージェント	1000	33%
順張りテクニカルエージェント	1500	50%
逆張りテクニカルエージェント	500	17%
ノイズエージェント	10000	-

表 2 本研究におけるエージェントタイプ別個数

### 3.2. その他の変数

エージェントタイプ別比率以外の変数は分析結果のスケールに影響はあるものの、結果の傾向そのものに対しては影響がないため、以下表 3 の通り、各変数を設定する。

変数名	定義	値
n	本来価値の周期	500
a	本来価値の平均	10000
A	本来価値の振幅	5000
d	本来価値からのずれの最大値	5%
r	リスク許容度の最大値	4%
l	テクニカルエージェントのずれの最大値	5%
m	最大参照期間	100
S	ノイズエージェント発注価格の分布幅	50%

表 3 各変数のパラメーター一覧

なお、取引制限については、下記表 4 の通りで行う。また、制限シナリオ 3 については、最適な取引制限の期間を探るために、表 5 のように、7 種類の制限頻度をシミュレーションする。

シナリオ	取引制限		
	ファンダメンタルエージェント	テクニカルエージェント	ノイズエージェント
1(自由シナリオ)	1	1	1
2(現実シナリオ)	10	1	1
3(制限シナリオ)	10	10	1

表 4 シミュレーションにおける取引制限

頻度パターン	1	2	3	4	5	6	7
取引制限頻度	3	5	10	15	20	25	30
本来価値の1周期との関係	3/500	1/100	1/50	3/100	2/50	1/20	3/50

表 5 取引制限シナリオ 3 の頻度

## 4. 結果と考察

20 回以上シミュレーション行っている結果は大きな差異がないため、任意の一つの結果をグラフでここに記載する。

本研究の結果の制限シナリオ 1 から 3 を同じ図 1、図 2 でまとめた。

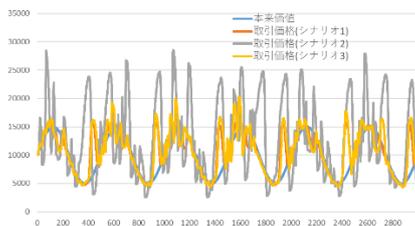


図 1 シナリオ 1 から 3 のまとめ

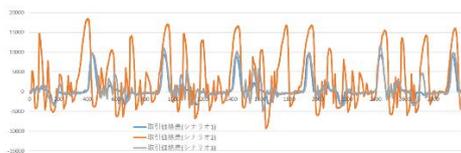


図 2 取引価格差(取引価格-本来価値)の推移

ファンダメンタルエージェントとテクニカルエージェントの取引頻度両方ともに制限した制限シナリオ 3 は両方ともに制限していない制限シナリオ 1 とほぼ近い結果となっており、本来価値からのずれも小さいという結果が得られている。取引頻度に一定の制限を加える方が、取引価格と本来価値をより近づける効果があるのではないかというシミュレーション結果が得られた。これは前述の REIT 上場によって日々のトレードが可能になったことに加え、HFT などによってテクニカルエージェントがファンダメンタルエージェントの取引可能な頻度を上回る頻度で取引するようになったことで、市場が却って不安定になったと言える。

今までの先行研究における、市場に規制を加えず、できるだけ流動性を供給することが市場価格の安定につながる研究結果[5][11]は一定の条件のもとでは、成り立たないことを示している。

## 5. まとめ

本研究では不動産業界にフォーカスし、取引頻度が取引価格に与える影響を人工市場モデルを用いて分析した。取引頻度を変更することで、取引価格と本来価値の差異の変化に注目した。

その結果、流動性の 1 要素である取引頻度が高いことは資産の本来価値に近い価格形成を必ずしもプラスの方向に寄与せず、一定の条件のもとではむしろマイナスになる可能性があることを、示唆した。これは不動産の REIT 化、株式の HFT 導入など今までの規制当局として、流動性を強化する方向とは異なる結果で、REIT に関する先行研究の一派の考えをサポートする内容となった。さらに、取引頻度が高いことは、本来価値に近い取引価格の形成に必ずしもプラスにならないこと、不動産市場においては、情報取得の頻度を考慮して、月 1 程度の頻度に取引頻度を制限した方が市場の効率性を高める可能性があることを示唆した。

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

- [1] B. LeBaron, (2006), "Agent-based financial markets: Matching stylized facts with style.", *Post Walrasian Macroeconomics Beyond the Dynamic Stochastic General Equilibrium Model*, Chapter 3, pages 221-238, Cambridge University Press
- [2] Isao Yagi, Takanobu Mizuta, (2018), "Analysis of the Impact of Leveraged ETF Rebalancing Trades on the Underlying Asset Market Using Artificial Market Simulation", SIG-FIN-018
- [3] I. Yagi, T. Mizuta, (2016), "Analysis of the impact of leveraged etf rebalancing trades on the underlying asset market simulation.", *Social Simulation Conference 2016 (SSC2016)*, September 2016
- [4] 神崎清志「商業用不動産の定量的評価手法およびリスク管理手法の研究」首都大学東京 社会科学研究所 博士論文 2014
- [5] Mizuta, T., Izumi, K., Yagi, I., Yoshimura, S., (2013), "Design of Financial Market Regulations against Large Price Fluctuations using by Artificial Market Simulations", *Journal of Mathematical Finance, Scientific Research Publishing*, Vol.3, No. 2A, pp.15-22.
- [6] Mizuta, T., Horie, S., (2018), "Mechanism by which active funds make market efficient investigated with agent-based model", *Evolutionary and Institutional Economics Review*
- [7] Robert John Kauffman, Yuzhou Hu, Dan Ma, (2015), "Will High-Frequency Trading Practices Transform the Financial Markets in the Asia Pacific Region?", *Research Collection School Of Information Systems*

[8] 祝迫得夫「日本における高頻度取引(High Frequency Trading)の現状について」 日本証券業協会 Working Paper

[9] 両宮卓史「株式等の高頻度取引—EU の法制度と我が国の制度案—」国立国会図書館 調査と情報—ISSUE BRIEF—No.960 (2017.4.21)

[10] 水田孝信, 八木勲, 和泉潔, 「現実の価格決定メカニズムを考慮した人工市場の設定評価手法の開発」, *人工知能学会論文誌*, Vol. 27, No. 6, pp.320-327, 2012.

[11] Mizuta, T., Kosugi, S., Kusumoto, T., Matsumoto, T., Izumi, (2015), "Effects of Dark Pools on Financial Markets' Efficiency and Price-Discovery Function: An Investigation by Multi-Agent Simulations", *Evolutionary and Institutional Economics Review*, Vol. 12, Issue 2, pp.375-394, 2015

# 遺伝的プログラミングによる市場価格変動の時系列モデルの構築

## Constructing Stochastic Model of Financial Markets using Genetic Programming

吉村勇志<sup>1</sup> 陳昱<sup>1</sup>

<sup>1</sup> 東京大学大学院新領域創成科学研究科人間環境学専攻

**Abstract:** 株式や外国為替等の金融市場において、特徴的な統計性質がいくつか知られており、それらの発生メカニズムを解明する為、様々なモデルが考案されてきた。ところが、研究者自身がモデル構築を行う場合、研究者が事前に想定した複雑さの因果関係までしかモデルに含むことが出来ない。そこで、遺伝的プログラミングによって、市場の統計性質を満たすようにモデルを自動生成する。本研究はその第一歩として fat tail と volatility clustering を再現する確率過程モデルの構築を行った。その結果、fat tail は比較的単純な式で再現出来るが、volatility clustering の再現には煩雑な式が要求されることが判明した。両者の同時再現においては要求される式の複雑さや誤差縮小速度の違いにより、ハイパーパラメータの細かな調整が必要である。

## 1. 序論

株式や外国為替等の金融市場において、fat tail (FT) や volatility clustering (VC) のような特徴的な統計性質がいくつか知られており、それらの発生メカニズムを解明する為、様々なモデルが考案されてきた、例えば ARCH[1]や GARCH[2]は確率過程で価格変動を表現し、Minority Game[3]やスピンモデル[4]のような人工市場は多数のトレーダーの集団的行動に、Maslov[5]や Farmer[6]は limit order book (LOB) のダイナミクスに注目している。これらのモデルは FT や VC の再現に多かれ少なかれ成功している。

ところが、市場に見られる統計性質は FT と VC のみに限られる訳ではない。モデルによって再現されるべき統計性質は他にも多数存在する。そして、再現すべき統計性質が多くなるに従って要求されるモデルの複雑さが増し、構築が難しくなることは言うまでもない。深層学習のような機械学習を用いればそのような複雑なモデルも構築出来る可能性はあるものの、モデルの中身を人間が解釈し、理論を一般化することが出来ない。そこで、遺伝的プログラミング(genetic programming; GP)[7]を用いて、市場の統計性質を再現し、尚且つ人間に可読な金融市場モデルの生成を試みる。

## 2. 背景

### 2.1 遺伝的プログラミングの要点

GP 自体は有名な手法であるので記述をしないが、

GP の条件設定に関しては十分に知られていないので簡単に要点を列挙する。これらは何れも文献[7]に基づく。

- ・ 解候補の多様性が必要であるから、個体数は最低でも 500 以上、可能ならば 1000 以上が望ましい
- ・ 進化計算の初期に本質的な改善を見せるので、世代数は 10 から 50 程度で十分
- ・ 新世代の生成は交叉で 90%、突然変異が 1%、残りが旧世代からそのまま引継ぎという割合が典型的ではあるが、突然変異が 50%等、全く異なる数値であっても問題ない
- ・ 交叉においては 2 つの式それぞれからランダムに 1 点選び、そこで取り換えるという subtree 選択が一般的、その際個数の多い終端子が選ばれ過ぎないように、例えば関数を 9 割、終端子を 1 割で選ぶようにする
- ・ 突然変異において最も簡単な方法は親となる式から 1 箇所を交叉と同様の方法で選び、ランダムに生成した式と取り換える subtree 突然変異である
- ・ 交叉や突然変異において親となる式はトーナメント選択によって行うことが多い
- ・ 式の初期生成においては ramped half-and-half で深さ上限 2-6 で作るのが一般的で、人口の半分は深さ上限まで成長させた式、残り半分は深さ上限の範囲内で確率的に成長させた式を用いる

### 2.2 生成対象の選択

GP は関数や終端子の取り得る範囲内において任意の数式、条件式を生成することが出来、またほぼ

全ての金融市場のモデルは複数の数式と条件式の組み合わせで記述可能である為、金融市場のモデルを対象に GP を実行することは不可能ではない筈である。

例えば、①エージェントが指値注文と成行注文のどちらを選択するかを条件式②指値注文の場合に注文する価格を算出する計算式③指値注文の数量を算出する計算式④成行注文の数量を計算する計算式、という 1 つの条件式と 3 つの数式を与えれば、それで 1 つの人工市場モデルを記述することが出来る。これだけでは売買方向を指定出来ないように見えるが、売買方向をランダムにする、他の数式の計算結果に依存して自動で決定する（指値注文であれば、高い価格は売り、低い価格は買いであると自動的に決め、成行注文の数量が正なら買い、負なら売りとする）等の方法を予め考え、用意しておけばシミュレーションを行うにあたって問題はない。売買方向を独立に決定したければ、モデルを記述する条件式を増やせば良い。キャンセル注文の導入も、同じく条件式や数式の追加で行うことが出来る。これら複数の式からなるモデルに対し、そのシミュレーション結果と実際の市場の統計性質の誤差を小さくするよう式を進化させる。

尤も、複数の式からなるモデルに GP を適用するには、問題及び GP の性質を深く理解し、それに応じた GP のテクニックの起用が必要となる。そこで、まずは最も単純なモデルとして、1 つの数式のみによって記述される確率過程モデルの生成を行う。

今回対象とする確率過程モデルの大枠を式(1,2)のように設定する。

$$\sigma(t) = f(r(t-1), r(t-2), \dots) \quad (1)$$

$$r(t) = \sigma(t)\varepsilon \quad (2)$$

式(1)は過去のリターンから標準偏差を計算する式で、(2)は計算された標準偏差の正規分布から次の時刻のリターンを計算する式で、 $\varepsilon$ は正規乱数である。式(1)の右辺を  $a + br^2(t-1)$  とすれば ARCH(1)に近い形となる。モデルを実質的に記述するのは(1)の右辺のみである為、非常に簡潔である。

このモデルを GP の対象として選ぶ利点は単純性の他にも存在する。価格変動に関する有名な統計性質には FT と VC の他にリターンの無相関性があるが、これに関しては式(2)により、目的関数に含めずとも自動的に満たされる筈である。モデルの構造故に、GP で生成する数式が満たすべき条件が緩和されている。また、GP の探索可能な範囲に ARCH に近いモデルが含まれている為、GP によって優れた確率

過程モデルが生成されなかった場合に、GP の条件設定やテクニックのみに原因を求めることが出来、モデル内の GP によって進化を行わない部分の不備によりどのような式を GP で生成しようとも理想的なモデルを決して作れないということがない。その上探索が上手くいけば、ARCH と異なり過去のリターンの高次の項が式中に現れ、従来知られていなかった複雑な時間相関を発見出来る可能性もある。

### 3 確率過程モデルの生成

#### 3.1 GP1 : VC 目的標準 GP

##### 3.1.1 条件設定

まずは最も簡単な条件下で GP による確率過程モデル生成を行った。条件は以下を除いて 2.1 と同じである。

- ・関数として加減乗除の 4 つを採用(除算において 0 は 1 を返すものとする)
- ・端子は 1-5 ステップ前までの過去のリターン及び定数から選択し、定数は-5 から+5 までの範囲から 0.1 刻みでランダムに選ばれる。端子が定数である確率が 5 割、過去リターンである確率が 5 割
- ・適合度はリターンの絶対値の自己相関を 100 ステップまで、日経平均のものとの誤差によって評価する。誤差は単純に差分の絶対値の総和とする。データの期間は 1991/1/4 から 2015/12/30 であり、日次の終値を使用した
- ・パラメータはトーナメント選択で競わせる解候補の数が 10、ランダムに式を成長させる時に関数になる確率が 5 割、端子が 5 割。個体数は 2000
- ・式のランダム生成における最大の深さを 5 とする
- ・端子が定数のみで構成され、定数しか返さない式が生成されないよう、何らかの操作で定数式が生じたら操作をもう一度やり直す

##### 3.1.2 結果

誤差は第 1 世代では 3.89 であったが、15 世代では 1.55 に低下した。進化計算によってモデルが改良されていることが分かる。GP が生成したモデルと日経平均の比較を図 1 に示す。時間遅れが 3-5 ステップ目の相関が強く出てしまっていることを除けば良好な結果である。尚、ランダム式生成における最大深さを 4 とすると誤差が 2.20 と大きくなり、再現が良好とは言えないことから、ボラティリティの時間相関にはある程度複雑な構造が必要だということが分かる。実際、生成された数式も本モデルにおいては

$((((\text{PrevR}(2)/3.8)-(((\text{PrevR}(3)/((\text{PrevR}(3)-\text{PrevR}(4))+\text{PrevR}(3))/-0.4))+4.4/((-0.1*\text{PrevR}(3))-((\text{PrevR}(4)+\text{PrevR}(3))*\text{PrevR}(3))))--3))-(((0.6+(((\text{PrevR}(5)+1.5)/(\text{PrevR}(4)+\text{PrevR}(3)))+0.9))*(-4.3+(\text{PrevR}(2)-\text{PrevR}(1))))+\text{PrevR}(1))/\text{PrevR}(2))+((\text{PrevR}(3)-\text{PrevR}(4))*(0.6/-1.3))+3.8)))-(((4.9+((1.9/\text{PrevR}(2))--2))-0.6+1.5)/(\text{PrevR}(4)+\text{PrevR}(3)))+((4.3*\text{PrevR}(5))/((\text{PrevR}(5)-3.4)-\text{PrevR}(5))))$ であるが、最大深さ 4 の場合には  $((-2.4-(\text{PrevR}(1)-(0.5/(1.5/(0.7*\text{PrevR}(5))))))*0.5/((5-2.1)+(0.6*(\text{PrevR}(4)-2.6))))-((-0.8*\text{PrevR}(5))-((-1.2+\text{PrevR}(3))+(-4.9/4.1))/2.1))$  であり、比較的単純な式であった。

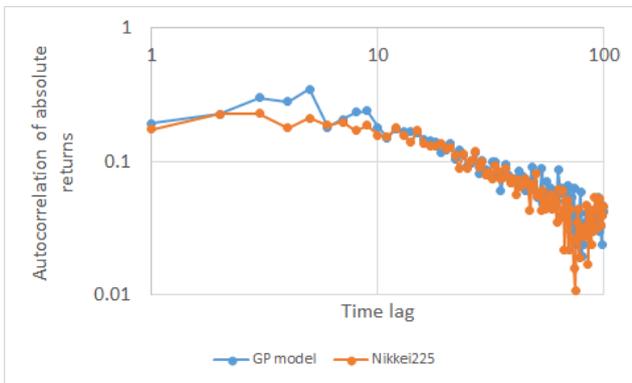


図 1 VC のみを目的関数とした標準的な GP が生成したモデルにおけるボラティリティの自己相関

### 3.2 GP2 : FT 目的標準 GP

#### 3.2.1 条件設定

次に目的関数を VC ではなく FT に変更する。使用する日経平均のデータにおいてリターンのサンプルサイズが 6135 であるから、シミュレーションの時間ステップ数も調整し、同じく 6135 個のリターンが観測されるようにし、リターンの絶対値の順に並び替え、シミュレーションと日経平均の誤差の総和を誤差関数として採用する。また、式のランダム生成における最大の深さを 4 とする。

#### 3.2.2 結果

誤差は第 1 世代では 6.41 だったのが、第 12 世代では 0.769 に低下した。FT に関しては VC よりも GP によるモデルの改善が良好であり、図 2 に示す通りリターンの絶対値の累積分布は現実の市場と極めて近い形状をしている。生成された式は  $((0.6/-4.5)-(\text{PrevR}(2)+\text{PrevR}(5))*(\text{PrevR}(5)+(\text{PrevR}(5)+0.1)))$ 、整理すると  $2r_{-5}^2 + 2r_{-5}r_{-2} + 0.367r_{-5} + 0.1r_{-2} + 0.0133$

となり、VC の再現と比べて FT の再現は遥かに単純な式で可能であるということが分かる。第 1 項は ARCH に近い形であるが、このモデルにおいてボラティリティの自己相関は弱かった。

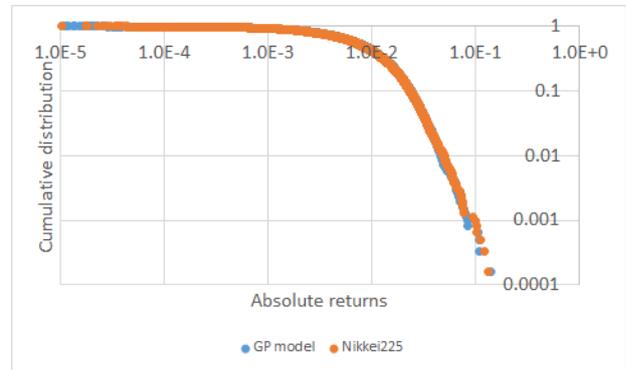


図 2 FT のみを目的とした標準的な GP が生成したモデルにおけるリターンの絶対値の累積分布

### 3.3 GP3 : FTVC 両目的標準 GP

#### 3.3.1 条件設定

誤差関数を式(3)のように、累積分布の誤差と自己相関の誤差の線形和で表現する。

$$E_{total} = E_{CDF} + cE_{ACF} \quad (3)$$

ここで、係数  $c = 8.9$  とする。ランダム式生成における最大深さは VC 再現の為、5 とする。

#### 3.2.2 結果

GP の 15 世代目のモデルのシミュレーション結果を図 3、4 に示す。

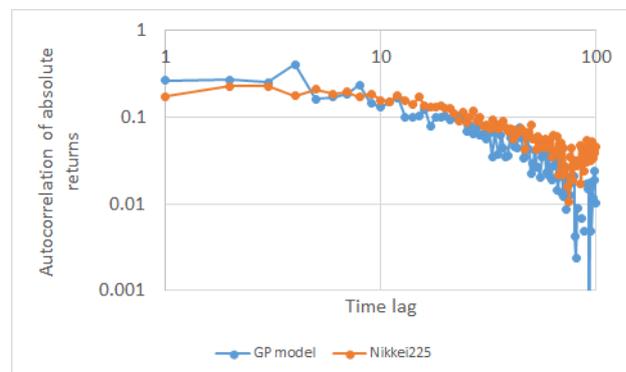


図 3 VC と FT を目的関数とした標準的な GP が生成したモデル及び日経平均におけるボラティリティの自己相関

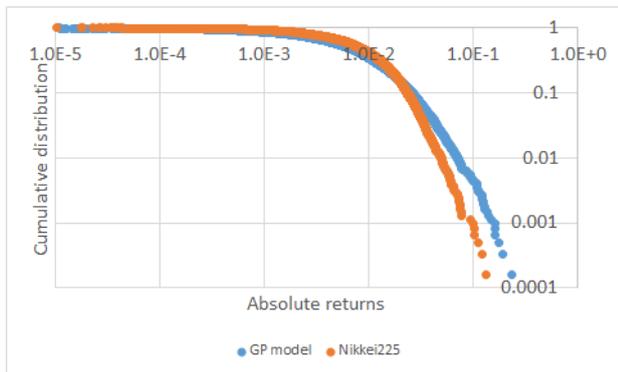


図3 VC と FT を目的関数とした標準的 GP が生成したモデル及び日経平均におけるリターン絶対値の累積分布

誤差の重み付け係数にも依存するが、VC か FT の一方の再現は、その片方のみを目的とした GP より劣り、両方を上手く再現する為には  $c$  の値を細かく調整する必要がある。今回進化計算で生成された式は  

$$\begin{aligned} & (((((\text{PrevR}(3)+\text{PrevR}(4))+(\text{PrevR}(4)+\text{PrevR}(2))))*4.1)/(- \\ & 3.6+(\text{PrevR}(3)-0.2)))-(((\text{PrevR}(2)+\text{PrevR}(1))-- \\ & 0.2)*(0.8*(\text{PrevR}(3)+(0.8*- \\ & 0.3)))))/(((\text{PrevR}(3)+\text{PrevR}(4))+(((\text{PrevR}(3)+\text{PrevR}(1))+1.6)-\text{PrevR}(3))*(\text{PrevR}(5)/(- \\ & 4.5/(0.8*((\text{PrevR}(4)+(\text{PrevR}(3)*\text{PrevR}(1)))+\text{PrevR}(2)))) \\ & )+\text{PrevR}(2))) \\ & ((((((\text{PrevR}(3)+(\text{PrevR}(2)+\text{PrevR}(1)))+(\text{PrevR}(4)+\text{PrevR}(2)))*\text{PrevR}(1))+(-3.8-(\text{PrevR}(3)*(\text{PrevR}(3)- \\ & 0.2))))*\text{PrevR}(1))+(-3.8-\text{PrevR}(5)))) \end{aligned}$$
であった。

3.1 及び 3.2 で示した通り VC の再現は複雑な式を用いないと困難で FT は比較的単純な式で可能であるが、この結果より FT は複雑な式においても再現が阻害されることはないということが分かった。

### 3.4 GP4：定数項分離型 GP

通常の GP は人間から見て明らかに解がないと分かるような解候補も探索している為に十分な結果を出しにくいと考え、本問題の構造に合わせ以下のように GP の条件設定を変更した。

- 1つのモデルの記述に1つの数式ではなく、1つの係数と1つの数式を用いて表現する
- GP により生成する数式の終端子は定数と過去のリターンを別個に扱うのではなく、定数と過去のリターンの積を1つの終端子として扱う
- 数式とは別個にモデルが持つ定数は交叉が行われる際に誤差に基づく重み付き平均により計算された値が新しい個体に与えられる。突然変異及び引継ぎ

においては親と同じ値を与える

このモデル改変の意図としては、この問題において GP で真に探索したいのは過去のリターン同士の複雑な関係であり、定数しか返さない定数同士の演算ではないので、定数倍の過去のリターン同士でのみ演算が起きるようにすることである。定数項に関しては何らかの最良の数値が存在すると仮定し、一旦最適解を得た後は変化しないように誤差による重み付き平均で更新することとした。

しかしながら、改変した GP は標準的な GP に勝る結果を出すことは出来なかった。ハイパーパラメータを式のランダム生成における最大深さを 4、終端子選択率を 20%、新世代生成において交叉 90%、突然変異 1% とした場合の標準的な GP よりかは高い性能を示したが、3.1 から 3.3 に示した結果とは明らかに劣る。

## 4 GP の経験的考察

GP は様々な問題点の発見と改良が行われているが、GP はハイパーパラメータに依存して出力する解が大きく変動する為、GP 改良のテクニックの導入の必要性は GP で扱う問題毎に検討されるべきである。

例えば、GP においては bloat (世代数が増えるにつれて数式のサイズが拡大し構造が複雑になっていくにも関わらず適合度の上昇が伴わない) が発生するということが知られており、その対策として Parsimony 係数(式のサイズに対しペナルティを科す) や Size fair 交叉や Shrink 突然変異等が提案されている。ところが、3.1.2 で示した通り、ランダム式生成における最大深さが 1 異なるだけで進化計算の結果得られる式のサイズが大きく異なるので、bloat の対策は特殊な技法を導入する前に GP のハイパーパラメータ調整で十分でないかを確認する必要がある。

また、式のランダム生成における最大深さを 4、終端子選択率を 20% とした場合の結果の悪さについては、初期の解候補の多様性が少ないのが原因であると考えられる。最大深さが小さく終端子選択率が低い(ランダムに生成した式が最大深さまで伸びやすい)程、最大深さまで多くの枝を伸ばした式ばかりが初期解として生成されてしまう。交叉や突然変異は現在の解候補の部分から新たな解候補を作る過程であるから、解候補は初期解から進化計算によりすぐに変化していくにも関わらず、その離れ方の不均一性が不足し、探索が上手くいかなかったのであろう。

## 5 GP の人工市場への応用の考察

3.2.2においてGPが2ステップ前と5ステップ前のリターンのみを利用してFTを再現する確率過程モデルを構築したように、GPが作り出すモデルにおいて使われる変数の選択は人間のそれとは大きく異なっている。人間であれば、1ステップ前のリターンを差し置いて2、5ステップ前のリターンを使ってモデルを作ることはないであろう。

このことはGPが人間ならば見落とすであろう市場の性質を捉える可能性だけでなく、表面的には正しそうに見えても人間から見れば明らかに間違っているモデルを生成する可能性も示唆している。例えば、エージェントが板情報を用いて取引を行う人工市場を構築した時、最良気配値と第二気配値の挙動が仮に似ていたとして、裁量気配値を用いずに第二気配値を用いて意思決定を行うモデルが構築されたとしたら、それは望ましいものとは言えない。これには3つの解決法が考えられる。

1つ目として、入力変数の独立性が高い条件下でGPを使うことである。例えば温度、圧力、経過時間から物質の物性値を予測するような問題であれば、温度の代わりに圧力が使われてしまうといった問題は起きないであろう。だが、このような制限された設定で構築出来る金融市場のモデルは数少ないが、一応存在し得ると考えている。例えば数学的に1人のトレーダーの最適行動を記述したモデルで、何らかの分布等、少数個の関数形さえ仮定すれば多数のエージェントで取引を行わせコンピューターシミュレーションを行えるようなものがあつた時、その少数個の関数形をGPで生成するというのは可能であると予想する。

2つ目として、再現する目標となる統計性質の数を増やすということが挙げられる。これはモデルが満たすべき条件を厳しくすれば小さな痾疲も見逃されなくなるだろうという考えに基づくが、多数の目標を立てると同時にそれぞれを満たすのが難しくなり、そのようなモデル自体構築出来ない可能性がある。この方法のみではあまり現実的ではない。

3つ目として、突然変異を subtree 突然変異のみにせず、式の構造を変えず終端子のみを僅かに変えるタイプの突然変異を導入することである。例えば、過去2ステップ前のリターンを参照する部分を、過去のリターンを参照するという部分は変えずに、それを3ステップ前に変える等がこれに該当する。これによって人間から見てより適切なモデルが調査から漏れるということのある程度防ぐことが出来ると期待される。もしこのような操作を経ても不自然なモデルの方が優れていた場合には、不自然なモデル

こそより優れていたと主張出来、理論の発展に貢献する可能性まであるかもしれない。

また、人工市場モデルの構築においてエージェントの行動規則をGPではなく他の技術により生成するというのも考えられる。確率過程モデルの場合、容易に数式が読めるのはFT再現のみを目的とした場合だけであり、VC再現が入ると数式の整理、読解に手間がかかる。そこで、例えば fast function extraction (FFX) [8]のように、関数及びそれらの一度の合成の線形和で数式を作るということも考えられる。この場合、一定以上に複雑な式が出てこず、理論への拡張性も高いと期待される。FFXは不要な項は係数推定と同時に自動的に削除されるアルゴリズムになっておりその点でも極めて利便性が高いが、FFXはモデルの生成に直接そのままの形では使えないので、改変が必要となる。

GP、改変型FFXの何れを使うにせよ、四則演算のみならず指数関数や対数関数等多数の関数をモデル生成に使うようになれば、シミュレーションという入力される数値の範囲が不確定な中で数値の発散等を如何に防ぐかというのも問題となってくる。

## 参考文献

- [1] Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica: Journal of the Econometric Society*, 987-1007.
- [2] Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of econometrics*, 31(3), 307-327.
- [3] Challet, D., Marsili, M., & Zhang, Y. C. (2000). Modeling market mechanism with minority game. *Physica A: Statistical Mechanics and its Applications*, 276(1), 284-315.
- [4] Iori, G. (1999). Avalanche dynamics and trading friction effects on stock market returns. *International Journal of Modern Physics C*, 10(06), 1149-1162.
- [5] Maslov, S. (2000). Simple model of a limit order-driven market. *Physica A: Statistical Mechanics and its Applications*, 278(3), 571-578.
- [6] Smith, E., Farmer, J. D., Gillemot, L. S., & Krishnamurthy, S. (2003). Statistical theory of the continuous double auction. *Quantitative finance*, 3(6), 481-514.
- [7] Poli, R., Langdon, W. B., McPhee, N. F., & Koza, J. R. (2008). *A field guide to genetic programming*. Lulu. com.
- [8] McConaghy, T. (2011). FFX: Fast, scalable, deterministic symbolic regression technology. In *Genetic Programming Theory and Practice IX* (pp. 235-260). Springer, New York, NY.

# 流動性リスク管理による 銀行ネットワーク安定化のシミュレーション分析

## Simulation Analysis of Bank Network Stabilization by Liquidity Risk Management

曾根泰平<sup>1</sup> 和泉潔<sup>2</sup> 坂地泰紀<sup>2</sup> 松島裕康<sup>2</sup> 島田尚<sup>2</sup>

Taihei Sone<sup>1</sup>, Kiyoshi Izumi<sup>2</sup>, Hiroki Sakaji<sup>2</sup>, Hiroyasu Matsushima<sup>2</sup>, and Takashi Shimada<sup>2</sup>

<sup>1</sup> 東京大学大学院工学系研究科技術経営戦略学専攻

<sup>1</sup> Department of Technology Management for Innovation,  
School of Engineering, The University of Tokyo

<sup>2</sup> 東京大学大学院工学系研究科システム創成学専攻

<sup>2</sup> Department of System Innovation, School of Engineering, The University of Tokyo

**Abstract:** The financial authorities around the world have been trying to prevent the occurrence of the financial crisis and to reduce the impact by creating a common framework for finance. In response to the Lehman shock that occurred in 2008, many financial institutions were forced to fail due to lack of liquidity, and from the reflection that not only the capital adequacy ratio regulation but also the liquidity ratio regulation is necessary, Basel III regulation consisting of the capital adequacy ratio regulation and liquidity ratio regulation was formulated in 2010. However, some problems are pointed out in the liquidity ratio regulation established under the Basel III regulation. Liquidity ratio regulation formulated under the Basel III regulation is trying to encourage banks to prepare for the financial crisis accompanying liquidity shock by ensuring adequate liquidity but this will lower the bank's asset management yield and it is feared that it may be a factor that puts pressure on management and, on the contrary, makes the financial system unstable. Therefore, in this research, we evaluate the influence of the liquidity ratio regulation on the Basel III regulation on the stability of the financial system by simulation. There are Liquidity Coverage Ratio (LCR) regulation and Net Stable Funding Ratio (NSFR) regulation in the liquidity ratio regulation on the Basel III regulation. In this research, we will examine the merits and demerits of the impact of the LCR regulation and the NSFR regulation, which is the liquidity ratio regulation of Basel III regulation, on the financial system.

### 1. はじめに

世界では金融に関する共通の枠組みを作ることで、金融危機の発生を予防したり影響の軽減を図ったりしてきた。2008年に起きたリーマン・ショックでは多くの金融機関が流動性の不足による破綻に追い込まれたことを受け、自己資本比率規制だけでなく流動性比率規制も必要だという反省から、自己資本比率規制と流動性比率規制から成るバーゼル III 規制が2010年に策定された[1][2]。

バーゼル III 規制における流動性比率規制は、主に金融システムにおけるシステムック・リスクの抑制を目的としている。システムック・リスクとは、個別の金融機関の支払不能等や、特定の市場または決済システム等の機能不全が、他の金融機関、他の

市場、または金融システム全体に波及するリスクのことをいう[3]。

ただし、バーゼル III 規制で策定された流動性比率規制にはいくつかの問題点が指摘されている。そのうちの一つである流動性カバレッジ比率(LCR)規制では、規制対象の銀行に対して、ストレス下の30日間における正味の資金流出に耐えられるだけの高品質な流動資産を保持するように求めている[4]。高品質な流動資産には例えば現金等が該当するが、従来個人や法人への貸付に回していた資金を手許に残しておく必要があるとなると、銀行の資産運用利回りが低下して経営を圧迫する可能性がある。また、同じくバーゼル III 規制で策定された流動性比率規制の一つである安定調達比率(NSFR)規制は、銀行の運用資金と調達資金の残存期間を一致させ、

資金の流入のタイミングを合わせることで流動性不足の発生を防ごうとするものである。しかし、元来銀行は預金者か

ら集めた短期かつ低金利で調達した資金を個人や法人に対して長期かつ高金利で貸し付けることで利益を得るビジネスモデルを採っており、銀行のビジネスに逆行しかねない安定調達比率(NSFR)規制は銀行の経営を圧迫するのではないかと危惧されている[5]。また、これらのバーゼル III 規制における流動性比率規制は現状では国際統一基準のみを対象としているが、わが国では競争の公平性の観点から将来的には国内の全銀行に適用することも検討されている。すると、財務基盤が安定していて経営体力のある都市銀行や主要地方銀行は当該規制による経営環境の悪化に耐えられるだろうが、資金調達能力や収益機会に乏しい弱小地方銀行は途端に窮地に追い込まれるのではないかと懸念がある。よって、バーゼル III 規制における流動性比率規制の導入が銀行の存続を脅かし、却って金融システムを不安定化させてしまうということも十分に考えられるため、その影響に関しては慎重な議論が必要だとされている。

そこで、本研究ではバーゼル III 規制における流動性比率規制の金融システムの安定性に与える影響についての評価を、シミュレーションを用いて行う。

## 2. モデル

### 2.1. 概要

本モデルは、Fig. 1 に示すように、銀行間ネットワーク、企業群、証券市場の3つの要素から構成される。それぞれの銀行が相互に貸借関係を結んで銀行間ネットワークを形成しており、さらにそれぞれの銀行は企業への融資や証券市場での投資を行っているという状況を想定している。

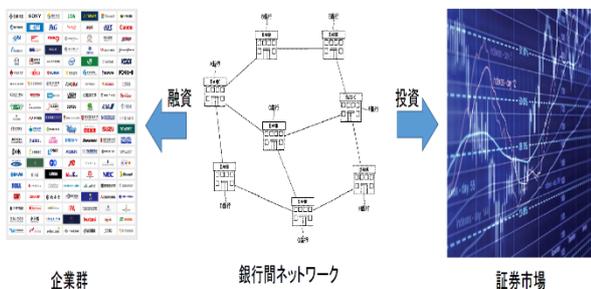


Fig. 1 モデルの概要 (出典：参考文献[6][7][8])

### 2.2. 銀行

#### 2.2.1. 銀行間ネットワーク

先行研究[9][10]によれば、我が国の銀行間ネットワークは scale-free network を形成している。そこで、銀行間ネットワークの形状として random network と scale-free network の2つを仮定する。ここで、random network は現実の銀行間ネットワーク構造に近い scale-free network との比較対象として導入している。

#### 2.2.2. 銀行のバランスシート

本モデルでは、銀行を100行用意し、銀行*i*に対してFig. 2に示すようなバランスシートを与えている。資産の部は、有価証券 $s_i$ 、銀行間貸出 $l_i$ 、企業融資 $e_i$ 、現金 $Gap_i$ から成る。負債の部は、預金 $d_i$ 、銀行間借入 $b_i$ 、自己資本 $c_i$ から成る。

さらに、銀行*i*のバランスシートは毎ステップで以下のように変化していく。

- ① 預金 $d_i$ の変動。
- ② 有価証券価格の変動に伴う有価証券 $s_i$ の変動。
- ③ 銀行間貸借に伴う銀行間貸出 $l_i$ と銀行間借入 $b_i$ の変動。
- ④ 企業への融資に伴う企業融資 $e_i$ の変動。
- ⑤ ①～④の結果を受けての現金 $Gap_i$ と自己資本 $c_i$ の変動。

現金 $Gap_i$ と自己資本 $c_i$ のいずれかが負に転じた場合、銀行*i*は破綻する。

	資産の部	負債の部
総資産 $a_i$	有価証券 $s_i$	預金 $d_i$
	銀行間貸出 $l_i$	銀行間借入 $b_i$
	企業融資 $e_i$	自己資本 $c_i$
	現金 $Gap_i$	

Fig. 2 銀行*i*のバランスシート

#### 2.2.3. 銀行間貸借

Fig. 3に示すように、銀行間貸借では資金に余剰のある銀行が資金の不足している銀行に対して資金を貸し出し、その対価として利息を受け取る。資金に余剰のある銀行は、バーゼル III 規制を逸脱しない範囲で他行に資金を貸し出すことができる。逆に、資金の不足している銀行は、バーゼル III 規制を満

たすことができるまで資金を借り入れようとする。

なお、銀行間貸借における金利は、先行研究[11]を参考にして式(1)で計算される。

$$r_{i,j} = r_0 + \left( \alpha \left( \frac{L_j(t)}{d_j(t)} \right)^{-\alpha} + \alpha \left( \frac{B_i(t)}{c_i(t)} \right)^{\alpha} \right) \log_{T+1}(t_d + 1) \quad (1)$$

ここで、 $r_{i,j}$ は銀行iの銀行jからの銀行間借入金利である。 $r_0$ は中央銀行金利で、0.0%である。そして、 $L_j(t)$ は時刻tにおける銀行jの余剰資産であり、バーゼル III 規制の充足度合いから逆算して算出される。 $d_j(t)$ は時刻tにおける銀行jの預金である。 $B_i(t)$ は時刻tにおける銀行iの負債であり、 $c_i(t)$ は時刻tにおける銀行iの自己資本である。また、 $\alpha$ はリスク感応度を示し、 $\alpha = 0.0050$ とする。そして、Tは銀行間貸借の満期の最大値であり、コール市場が1年以内の資金貸借の市場であることから、1年を250日営業日と捉えて $T = 250$ とした。 $t_d$ は銀行間貸借の満期を示し、 $1 \leq t_d \leq 250$ である。

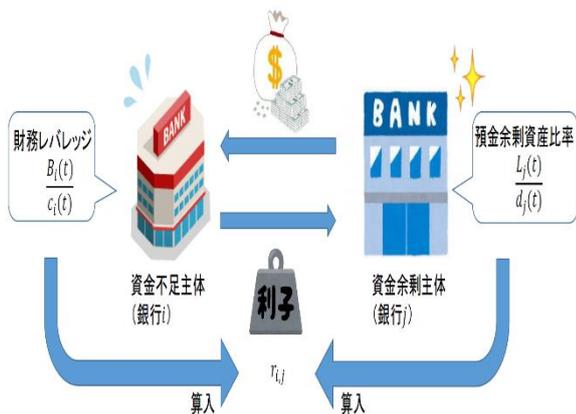


Fig. 3 銀行間貸借のイメージ

#### 2.2.4. 銀行の破綻処理

銀行は、自己資本 $c_i$ と現金 $Gap_i$ のいずれかが負になった場合に破綻する。銀行iが破綻した場合、銀行iに資金を貸し出していた銀行jは貸出債権の焦げ付きを被り、銀行iへの貸出額と同額だけ自己資本が毀損する。また、破綻した銀行iの資産を整理するため、銀行iへ貸付を行っていた銀行jは、銀行iの銀行借入に対する自身の貸出額の比率に応じて銀行iの資産を継承する。同様に、銀行iの預金も引き継ぐ。

#### 2.2.5. バーゼルIII規制

バーゼル III 規制は自己資本比率規制と流動性比率規制から成る。まず、自己資本比率規制では、リスク資産に対する自己資本の比率が一定値以上になるように求めている。次に、流動性比率規制の一つ

である流動性カバレッジ比率 (LCR) 規制では、30日間の正味資金流出額に対する高品質な流動資産 (現金や有価証券等) が一定値以上になるように求めている。最後に、流動性比率規制のもう一つの規制である安定調達比率 (NSFR) 規制では、運用資金に対する調達資金が一定値以上になるように求めている。なお、このとき運用資金と調達資金は、それぞれ残存期間別に重み付けがなされた上で算出されている。本モデルでは、参考文献[12][13][14]をもとに、バーゼル III 規制におけるこれらの規制を表現した。

### 2.3. 企業

#### 2.3.1. 銀行企業間ネットワーク

参考文献[15]によると、大手行ほど取引先企業数も多いことが分かっている。そこで、本モデルでもシミュレーション開始時点では資産規模の大きい銀行ほど多くの取引先企業を有するように銀行企業間ネットワークを生成している。なお、シミュレーション開始後は、それぞれの企業と銀行の行動に応じて銀行企業間ネットワークは逐次変化していく。

#### 2.3.2. 企業のバランスシート

本モデルでは、企業を100社用意し、企業i'に対してFig. 4に示すようなバランスシートを与えている。資産の部は、資産 $a_i$ から成り、幾何ブラウン運動に従って変動する。負債の部は、銀行間借入 $b_i$ 、自己資本 $c_i$ から成る。

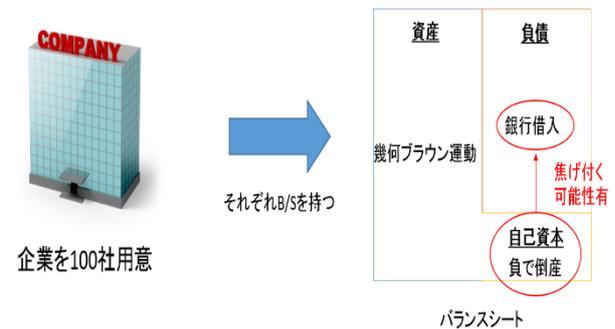


Fig. 4 企業i'のバランスシート

#### 2.3.3. 銀行による企業への融資

それぞれの企業の資産は幾何ブラウン運動(式(2))に従い、それに伴って企業の資金需要(式(3))も決定される。

$$dA_t = \mu A_t dt + \sigma_1 A_t dW_{t,1} \quad (2)$$

ただし、 $\mu$ 、 $\sigma_1$ はそれぞれ企業の資産価値伸び率のドリフト、ボラティリティであり、 $A_t$ は時刻tにおける企業

の資産である。また、 $W_{t,i}$ は標準ブラウン運動である。ここでは、先行研究[16]に倣い $\mu = 0.05$ ,  $\sigma_1 = 0.10$ とした。

$$\Delta E_t = b\Delta t + D_+\Delta A_t l_{\Delta A_t \geq 0} + D_-\Delta A_t l_{\Delta A_t < 0} + \sigma_2 \sqrt{\Delta t} \varepsilon_{t,2} \quad (3)$$

ここで、 $l_{\Delta A_t \geq 0}$ は $\Delta A_t \geq 0$ が真であるとき 1 をとり、それ以外のときは 0 をとる。同様に、 $l_{\Delta A_t < 0}$ も $\Delta A_t < 0$ が真であるとき 1 をとり、それ以外のときは 0 をとる。これにより、式(3)では直近の企業価値の変化に対し、企業価値上昇時は $D_+\Delta A_t$ 、企業価値減少時は $D_-\Delta A_t$ の資金需要が生じると想定している。ただし、企業価値の変動がない( $=\Delta A_t=0$ )の場合でも、負債が趨勢的に増加・減少することもあり得るため、時間トレンド項 $b\Delta t$ を含む。また、確率項 $\sigma_2 \sqrt{\Delta t} \varepsilon_{t,2}$ により資金需要 $\Delta E_t$ を確率過程として表現している。ここで、 $\sigma_2$ は資金需要の不確実性を表すボラティリティで、 $\sigma_2 = 0.07$ であり、 $\varepsilon_{t,2}$ は標準正規分布に従う確率変数である[16]。また、 $b = 2.0$ ,  $D_+ = 1.0$ ,  $D_- = 0.0$ である[16]。さらに、 $\Delta t = 0.004$ である[17]。

#### 2.3.4. 企業の破綻処理

企業は、自己資本 $c_i$ が負になった場合に破綻する。ある企業が破綻した場合、当該企業に資金を貸し出していた銀行は貸出債権の焦げ付きを被り、当該企業への貸出額と同額だけ自己資本が毀損する。

### 2.4. 有価証券

#### 2.4.1. 銀行による有価証券への投資

本モデルでは、100 銘柄の有価証券が証券市場で取引されているものとする。なお、証券市場の参加者は銀行のみである。有価証券投資では、まず各銀行が有価証券を買うのか売するのかの意思決定を行い (Fig. 5 参照<sup>1)</sup>)、次に売買注文を出す銘柄を決め、すべての銀行の注文を集計して約定処理を行う。そして、これらの一連の銀行による有価証券取引の結果を受けて、各有価証券銘柄の価格が変動する。

なお、売買銘柄の決定は式(4)に基づき、有価証券価格の変動は式(5)に基づく。

$$EU_{i,k} = \bar{r}_k - \frac{1}{2} \lambda_i \sigma_k^2 \quad (4)$$

ここで、 $EU_{i,k}$ は銀行*i*にとっての有価証券*k*の評価値を、 $\bar{r}_k$ と $\sigma_k$ はそれぞれ過去*m*日間の有価証券*k*の平均リターンと標準偏差を、 $\lambda_i$ は銀行*i*のリスク回避度を示す。

<sup>1</sup> ここで、過去*m*日間の全有価証券銘柄のリターンの平均と標準偏差をそれぞれ $r_{exp}$ ,  $\sigma_m$ , 銀行*i*のリスク回避度を $\lambda_i$ とする

$$P_{k,t} = P_{k,t-1} + r_f P_{k,t-1} \Delta t + \sigma P_{k,t-1} \tilde{\varepsilon} \sqrt{\Delta t} \quad (5)$$

ここで、 $P_{k,t}$ は時刻*t*における有価証券*k*の価格を、 $r_f$ はリスクフリーレートを、 $\sigma$ はボラティリティを示し、 $r_f = 0.02$ ,  $\sigma = 0.25$ ,  $\Delta t = 0.004$ である[17]。また、 $\tilde{\varepsilon} \sim N\left(\frac{buyOrder_k(t) - sellOrder_k(t)}{totalStock_k(t)}, 1\right)$  であり、 $buyOrder_k(t)$ は時刻*t*における有価証券*k* に対する買い注文量を、 $sellOrder_k(t)$ は時刻*t*における有価証券*k*に対する売り注文量を、 $totalStock_k(t)$ は時刻*t*における有価証券*k*の発行済株式数を示す。



Fig. 5 有価証券投資における意思決定の基準

## 3. 金融システムの安定性に対するパーゼルⅢ規制における流動性比率規制の影響についてのシミュレーション

### 3.1. 共通設定

シミュレーション中の 1 ステップの流れは、Fig. 6 に示す通りである。各ステップにおいて、①～⑦の処理を繰り返す。本研究では 1 試行 125 ステップのシミュレーションをパラメータセットごとに 30 試行行う。これは、1 年間を 250 日営業日と捉え、銀行勘定の予算・決算期間である半年を想定した設定である[17]。

と、相場観*f*は以下の通り表される；

$$f = r_{exp} - \sin(\lambda_i) + \sigma_m$$

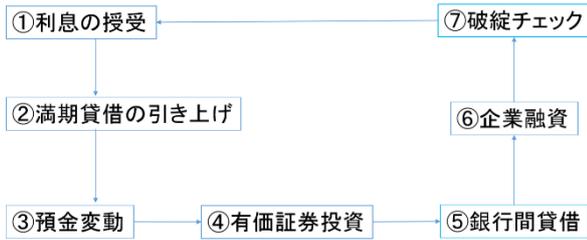


Fig. 6 シミュレーション中の1ステップの流れ

### 3.2. モデルの妥当性検証

モデルの妥当性検証では、預金変動における流動性ショックの大きさ $\phi$ と銀行破綻数の関係を取り上げた。妥当なモデルであれば、流動性ショックの大きさ $\phi$ が大きくなるほど銀行破綻数も大きくなるはずである。Fig. 7を見ると、確かに流動性ショックの大きさ $\phi$ が大きくなるほど銀行破綻数も大きくなっており、想定していた通りに妥当な結果が得られた。ここで、自己資本要因破綻とは自己資本 $c_i$ が負になることによる破綻であり、流動性要因破綻とは現金 $Gap_i$ が負になることによる破綻である。そして、総破綻はそれらの和である。

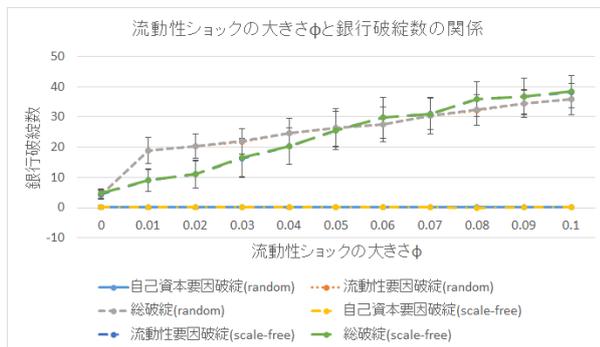


Fig. 7 流動性ショックの大きさ  $\phi$  と銀行破綻数の関係

### 3.3. 流動性カバレッジ比率（LCR）規制の

#### 感度分析

random network と scale-free network のそれぞれにおいて、LCR 規制の規制範囲と規制水準を変化させたときの銀行の総破綻数の変化を Fig. 8～Fig. 11 に示す。Fig. 8 では、LCR 規制の規制範囲を変化させても総破綻数はあまり変化していない。これは、銀行間貸借関係を有していない孤立した銀行の多い random network では、LCR 規制の規制範囲を変化させても銀行間貸借行動にあまり変化がないためである。Fig. 9～Fig. 11 では、LCR 規制の規制範囲や規

制水準を上げると、総破綻数が増加している。これは、LCR 規制の規制範囲や規制水準を上げることによって、金融システムにおける流動性供給に対して流動性需要が増加したことによる。

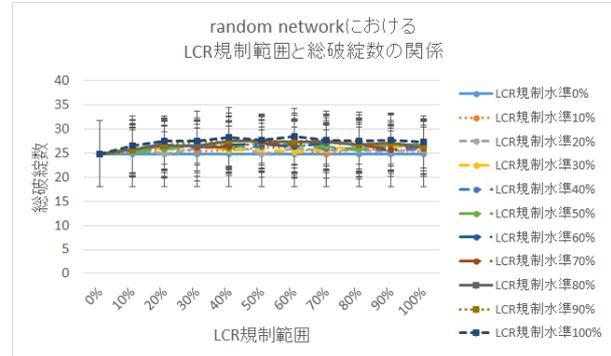


Fig. 8 random network における LCR 規制範囲と総破綻数の関係

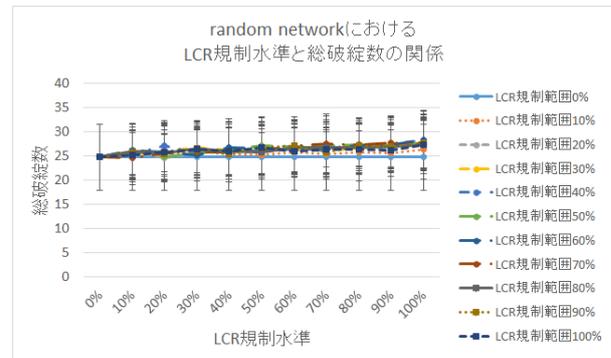


Fig. 9 random network における LCR 規制水準と総破綻数の関係

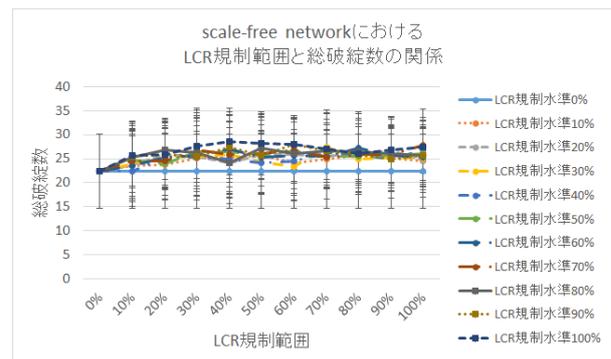


Fig. 10 scale-free network における LCR 規制範囲と総破綻数の関係

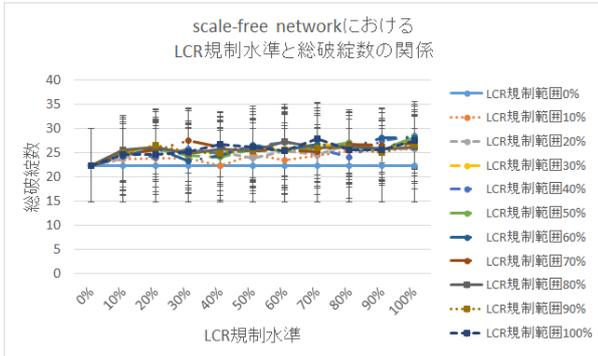


Fig. 11 scale-free network における LCR 規制水準と総破綻数の関係

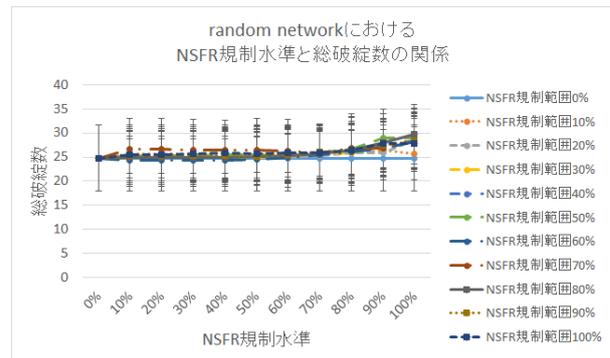


Fig. 13 random network における NSFR 規制水準と総破綻数の関係

### 3.4. 安定調達比率（NSFR）規制の感度分析

random network と scale-free network のそれぞれにおいて、NSFR 規制の規制範囲と規制水準を変化させたときの銀行の総破綻数の変化を Fig. 12～Fig. 15 に示す。Fig. 12 では、NSFR 規制の規制範囲を変化させても総破綻数はあまり変化していない。これは、銀行間貸借関係を有していない孤立した銀行の多い random network では、NSFR 規制の規制範囲を変化させても銀行間貸借行動にあまり変化がないためである。Fig. 13 では、NSFR 規制の規制水準を引き上げると、総破綻数が増加している。これは、NSFR 規制の規制水準の引き上げにより、流動性需給が逼迫したり、資金調達コストが高くなりすぎたことに起因する。Fig. 14 と Fig. 15 を見ると、scale-free network では NSFR 規制の規制範囲と規制水準がともに高いと、総破綻数が抑制されていることが分かる。これは NSFR 規制の規制範囲と規制水準の引き上げにより、多くの銀行が長期資金を調達することで流動性ショックに対する頑健性が増したからである。ただし、NSFR 規制の規制範囲と規制水準の引き上げにより、資金調達コスト増加による銀行破綻も一部で起きている。

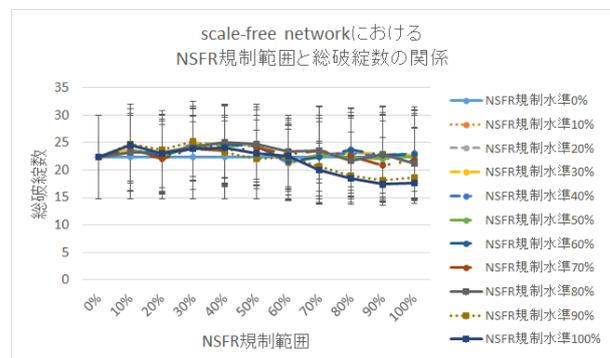


Fig. 14 scale-free network における NSFR 規制範囲と総破綻数の関係

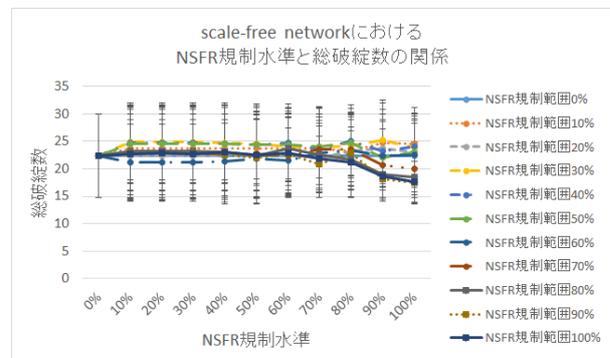


Fig. 15 scale-free network における NSFR 規制水準と総破綻数の関係

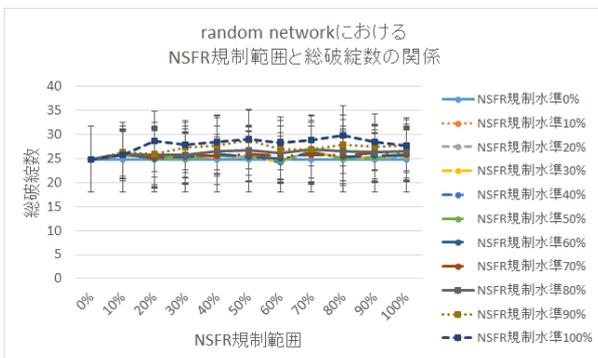


Fig. 12 random network における NSFR 規制範囲と総破綻数の関係

## 4. おわりに

まず、LCR 規制の規制範囲と規制水準を引き上げることによる金融システム安定化効果についてまとめる。本研究では、scale-free network で LCR の規制範囲と規制水準を引き上げると銀行破綻数が増加することが分かった。よって、LCR 規制の規制範囲と規制水準の引き上げは、金融システムの資金融通機能を制約するばかりで、単独では流動性ショックに

対する金融システムの頑健性を高める効果はなく、却って金融システムを不安定化させる恐れがあると言える。

次に、NSFR 規制の規制範囲と規制水準を引き上げることによる金融システム安定化効果についてまとめる。本研究では、scale-free network で NSFR 規制の規制範囲と規制水準を引き上げると銀行破綻数が減少することが分かった。よって、現実の金融システムでも NSFR 規制の規制範囲と規制水準を引き上げると、金融システムを安定化させる効果が得られると考えられる。ただし、NSFR 規制の規制範囲と規制水準の引き上げにより一部の銀行に起こった自己資本要因破綻の重要性や影響の評価については議論の余地がある。

本研究の今後の課題として、モデルの改良とシミュレーション結果のさらなる検証が挙げられる。

まず、モデルの改良の可能性について述べる。先行研究[10], [18]によると、現実の銀行間ネットワークには scale-free 性だけでなく small-world 性も認められるようである。よって、本研究で行ったシミュレーションを small-world network にも適用することが改良点の一つとして挙げられる。また、LCR 規制や NSFR 規制で積み上げた資金は、金融危機時には取り崩して使用することが許されているため、その影響を考慮したシミュレーションも行う余地がある。さらに、金融危機時には政府・中央銀行による銀行救済措置も取られる他、LCR や NSFR 規制には政府・中央銀行による銀行救済コストの低減効果も期待されているため、その点も追究の余地がある。

## 謝辞

本研究は、筆者が東京大学大学院工学系研究科技術経営戦略学専攻修士課程在籍中に和泉・坂地研究室にて行った研究をまとめたものです。本研究を行うにあたり御世話になった方々に、この場を借りて御礼を申し上げます。主査の和泉潔教授には、本研究に関して終始御指導御鞭撻を頂きました。副査の古田一雄教授には、本稿を御精読頂き有用なコメントを頂きました。島田研究室の島田尚准教授、和泉・坂地研究室の坂地泰紀特任講師、松島裕康特任助教授には、研究室内のゼミや勉強会にて貴重な御意見を頂きました。和泉・坂地研究室の山本由香秘書には、研究室の運営や環境の改善・維持を通して研究活動を支えて頂きました。和泉・坂地研究室に在籍する濱脇諒君と松浦出君には、本稿を度々校閲して頂きました。その他の和泉・坂地研究室に在籍する皆様とも、数多くの有益な議論をさせて頂き、また、研究外においても交流を深められたことで、楽しく充実し

た研究生生活を送ることができました。皆様の御陰で本研究を完遂することができましたことを心より感謝いたします。最後に、いつも筆者を支えて頂いた家族・友人に深謝の意を表します。

## 参考文献

- [1] SMBC 日興証券ホームページ, URL:<https://www.smbcnikko.co.jp/terms/japan/ha/J0710.html>(参照日:2019年1月4日)
- [2] 鈴木利光:「パーゼル III の初歩第 16 回「安定調達比率とは?」」, URL:[https://www.dir.co.jp/report/research/introduction/financial/basel3/20150210\\_009423.pdf](https://www.dir.co.jp/report/research/introduction/financial/basel3/20150210_009423.pdf)(参照日:2019年1月4日), (2015)
- [3] システムック・リスクとは何ですか?, URL:<https://www.boj.or.jp/announcements/education/oshiete/kess/i06.htm/>(参照日:2019年1月7日)
- [4] 花井ゆき子:「パーゼル III 対応型の台頭で注目されるハイブリッド証券」, URL:[https://www.alliancebernstein.co.jp/files/uploads/Context\\_20140526.pdf](https://www.alliancebernstein.co.jp/files/uploads/Context_20140526.pdf)(参照日:2018年9月14日), (2014)
- [5] 金融庁/日本銀行:「安定調達比率(NSFR)市中協議文書,流動性カバレッジ比率(LCR)への追加事項の概要」, URL:<https://www.fsa.go.jp/inter/bis/20140115-1/03.pdf>(参照日:2019年1月7日), (2014)
- [6] 知財ポータルサイト IPForce, URL:<https://ipforce.jp/patent-jp-B9-6243488>(参照日:2018年9月27日)
- [7] web 製作会社 ティファナ, URL:<https://www.tifana.com/company/client.html>(参照日:2018年9月27日)
- [8] coconala, URL:<https://coconala.com/services/248219>(参照日:2018年9月27日)
- [9] 稲岡創, 二宮拓人, 谷口健, 清水季子, 高安秀樹:「金融機関の資金取引ネットワーク」, 日本銀行金融市場局ワーキングペーパーシリーズ, Vol.2003-J, No.2, pp.1-28, (2003)
- [10] 今久保圭, 副島豊:「コール市場の資金取引ネットワーク」, 日本銀行金融研究所ディスカッションペーパー, Vol.2008-J, No.16, pp.47-100, (2008)
- [11] Minghui Zhang., Jianmin He., and Shouwei Li.:「Interbank lending, network structure and default risk contagion」, Physica A, Vol.493, No.2018, pp.203-209, (2018)
- [12] 金融庁/日本銀行:「安定調達比率(Net Stable Funding Ratio:NSFR)最終規則の概要」, URL:[https://www.boj.or.jp/announcements/release\\_2014/data/rel141105a1.pdf](https://www.boj.or.jp/announcements/release_2014/data/rel141105a1.pdf)(参照日:2018年9月14日),

(2015)

- [13] みずほ総合研究所: 国際的な金融規制改革の動向 (13 訂版), URL:<https://www.mizuho-ri.co.jp/publication/research/pdf/urgency/report180723.pdf> (参照日: 2018 年 9 月 14 日), (2018)
- [14] 木利光: 流動性カバレッジ比率(LCR)の告示案, URL:[https://www.dir.co.jp/report/research/law-research/regulation/20140911\\_008934.pdf](https://www.dir.co.jp/report/research/law-research/regulation/20140911_008934.pdf)(参照日: 2018 年 9 月 14 日), (2014)
- [15] 東京商工リサーチホームページ, URL:[http://www.tsr-net.co.jp/news/analysis/20170804\\_01.html](http://www.tsr-net.co.jp/news/analysis/20170804_01.html) (参照日: 2018 年 10 月 3 日).
- [16] 藤原茂章: エクスポーシチャーの変動を考慮した信用リスク評価:コミットメントラインの応用, 日本銀行金融研究所ディスカッションペーパー, Vol.2007-J, No.29, pp.113-138, (2007)
- [17] 菊地剛正, 國上真章, 山田隆志, 高橋大志, 寺野隆雄: エージェントシミュレーションを用いた金融規制が金融機関の連動的な破綻に与える影響の分析, 人工知能学会論文誌, Vol.31, No.6, pp.1-11, (2016)
- [18] Co-Pierre Georg.: The effect of the interbank network structure on contagion and common shocks, *Journal of Banking & Finance*, Vol.37, No.7, pp.2216-2228, (2013)