

金融情報学研究会(第21回)

日時 2018年10月20日(土)

会場 東京大学 浅野キャンパス 武田先端知ビル 武田ホール

SIG-FiN
JSAI Special Interest Group on
Financial Informatics

人工知能学会
金融情報学研究会

第21回 人工知能学会 金融情報学研究会 (SIG-FIN)

2018年10月20日(土) 東京大学 浅野キャンパス 武田先端知ビル 武田ホール

01. 水平株式保有するパッシブファンドの増加が企業間競争と市場価格へ与える影響 …………… 1
—人工市場によるシミュレーション分析—
水田孝信(スパークス・アセット・マネジメント)
02. 人工市場を用いた分散投資規制が市場に与える影響分析 …………… 8
～ファンダメンタル価格急落時と急騰時における比較～
丸山隼矢(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)
03. 深層学習を用いたマルチファクター運用の実証分析 …………… 16
阿部真也(野村アセットマネジメント), 中川慧(野村アセットマネジメント)
04. 外国為替市場におけるトレーディング戦略分類 …………… 21
末重拓己(東京工業大学), 金澤輝代士(東京工業大学),
高安秀樹(東京工業大学, 明治大学, Sony CSL), 高安美佐子(東京工業大学)
05. 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 …………… 24
常井祥太(東京都市大学), 穴田一(東京都市大学)
06. テクニカル指標による金融取引の戦略的構築 …………… 29
加藤旺樹(東京都市大学), 穴田一(東京都市大学)
07. アセット・リターン予測 AI とマクロ経済理論の融合 …………… 33
—マルチタスク学習による正則化と識別—
塩野剛志(クレディ・スイス証券)
08. 人工知能を用いた株価下落リスクの予兆管理 …………… 41
石原龍太(かんぽ生命保険)
09. 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 …………… 46
水門善之(野村証券金融経済研究所)
10. 高頻度注文情報の時系列性考慮による短期市場動向予測 …………… 50
前田巖(東京大学), 松島裕康(東京大学), 坂地泰紀(東京大学), 和泉潔(東京大学),
David deGraw(大和証券), 富岡博和(大和証券), 加藤惇雄(大和総研)
11. カバー先銀行の集合知による外国為替ベストレート予測 …………… 53
鈴木丈裕(茨城大学), 矢野和洞(茨城大学), 鈴木智也(茨城大学, コラボウィズ株式会社)

12. 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	59
坂地泰紀(東京大学), 和泉潔(東京大学), 松島裕康(東京大学)	
13. 有価証券報告書からの事業セグメントごとの業績要因文・業績結果文の抽出	61
高野海斗(成蹊大学), 酒井浩之(成蹊大学), 北島良三(成蹊大学)	
14. 適時開示情報の業績に対するリスク有無の自動判定	66
矢野大輔(成蹊大学), 酒井浩之(成蹊大学), 北島良三(成蹊大学), 広井康男(QUICK), 村山勉(QUICK), 河合継(クリスタルメソッド), 西山昇(Dragons' Desk/千葉商科大学)	
15. 決算短信における業績要因・業績結果の因果関係の抽出	71
加藤悠太(成蹊大学), 酒井浩之(成蹊大学), 坂地泰紀(東京大学), 北島良三(成蹊大学), 江口潤一(大和証券投資信託委託)	
16. 為替情報の幾何的特徴を用いた売買アルゴリズムの検討	76
河合継(クリスタルメソッド), 新田翔(東京理科大学), 山口航(東京工業大学), 木村祐輔(東京大学), 西山昇(千葉商科大学)	
17. 金融時系列のための深層 t 過程回帰モデル	82
中川慧(野村アセットマネジメント), 角屋貴則(MAZIN, Inc.), 内山祐介(MAZIN, Inc.)	
18. ビットコイン価格時系列の統計的性質	87
高石哲弥(広島経済大学)	
19. 一般顧客の集合知による外国為替交換レート予測	93
矢野和洞(茨城大学), 鈴木丈裕(茨城大学), 鈴木智也(茨城大学, コラボウィズ株式会社)	

水平株式保有するパッシブファンドの増加が 企業間競争と市場価格へ与える影響 —人工市場によるシミュレーション分析— Effect of Increasing of Horizontal Shareholding by Index Funds to Competitions and Market Prices — Investigation by Agent-Based Model —

水田孝信*1

Takanobu Mizuta

*1 スパークス・アセット・マネジメント株式会社

SPARX Asset Management Co., Ltd.

近年、投資ファンドがある業界のすべての企業の大株主となる“水平株式保有”(horizontal shareholding)(または“共同保有”(common ownership)ともよばれる)が、公正な企業間の競争を阻害し、産業の発展を妨げているという主張が増えてきた。特にパッシブファンドによる水平株式保有が大きな割合となっており、大きな議論となっている。本研究では、人工市場モデルを用いてパッシブファンドの増加が企業間競争と市場価格へ与える影響を分析した。その結果、パッシブファンドの割合がさほど大きくなくても、競争を阻害する可能性を示した。また、競争に勝った企業の市場価格が増加したファンダメンタル価格以上に上昇して割高となり競争を促す株主が離れて競争力を弱くする一方、競争に負けた企業の市場価格が減少したファンダメンタル価格よりさらに下落して割安となり競争を促す株主が増え競争力を強くして、企業間競争のバランスをとるメカニズムが存在する可能性があることを示した。パッシブファンドの増加はこのようなメカニズムを弱める恐れがあると考えられる。

1. はじめに

近年、投資ファンドがある業界のすべての企業の大株主となる“水平株式保有”(horizontal shareholding)(または“共同保有”(common ownership)ともよばれる)が、公正な企業間の競争を阻害し、産業の発展を妨げているという主張が増えてきた [Azar 14, Elhauge 16, Fichtner 17]*1。通常投資家は、保有している企業が競争に勝ち企業価値が上昇することが自身の利益につながるため、企業の経営者に競争を促す。一方、業界のすべての株式を保有している投資家は保有する企業間が競争することによって、たとえある企業が競争に勝っても競争に負けた方の企業も必ず保有しており、その企業の価値下落によって損失もこうむるので競争を促す動機がなく、むしろ商品の販売価格を維持する方が利益になることすらある。

水平株式保有はさまざまな投資戦略のファンドで起こりえるが、日経平均株価などの指数(インデックス)と同じ収益を得られるようにインデックスを構成する銘柄と同じ銘柄を保有する“パッシブファンド”はほとんどの場合水平株式保有を行ううえ、近年急速に投資資金が増えているため、特にパッシブファンドによる水平株式保有が大きな割合となっており、大きな議論となっている [Fichtner 17]*2。

米国においてはパッシブファンドの運用会社は上位3社による連絡先: 本稿は [水田 18b, Mizuta 18d] を再構成したものです
水田 孝信, mizutata@gmail.com

<http://mizutatakanobu.com>

当日の発表スライドは以下にあります

<http://mizutatakanobu.com/20181020.pdf>

*1 これらの論文のレビューもある [水田 18a, 水田 18c].

*2 近年のパッシブファンド急増への懸念は他にもある。パッシブファンドに対して値上がり期待できる銘柄を選別しそれらに投資する“アクティブファンド”とよぶが、アクティブファンドは投資先企業に本源的に存在する価値(ファンダメンタル価値)に基づいて取引を行うため、企業価値に即した適正な価格を発見し、その価格付近に市場価格を近づける(市場を効率的にする)という、資本主義の重要な機能である投資資本の適切な配分を担っているという主張がある(優れたレビューとして [Wurgler 10])。そのため、アクティブファンドが減りパッシブファンドが増えることは、市場価格が適切

る寡占が進んでいるうえ、全上場企業の4割以上の企業の筆頭株主が実質的にパッシブファンドの運用会社で、パッシブファンドが全体の約15%を保有し、多くの企業の上位株主が重複しているという状況になっている [Fichtner 17]。このため [Azar 14] は、米国航空業界では上位株主の多くが重複しており、この水平株式保有による企業間競争の阻害の効果で航空運賃が3%から7%ほど高くなっていると見積もった。[Fichtner 17] は議決権行使の状況を分析し、パッシブファンドは株主総会のような公開の場ではなく、経営者との非公式ミーティングの場で経営者へ圧力をかけていると主張した。

[Elhauge 16] は、このような状況はすでに反トラスト法(日本でいう独占禁止法)に違反している状況である恐れがあると述べ、[Piketty 13] が主張する所得格差の拡大はパッシブファンドが企業間競争を阻害していることが原因であって*3、これ以上の所得格差の拡大を食い止めるためには、株式に投資するファンドに対して1業界につき1企業のみに保有を制限すべきと主張した。

しかしながら、水平株式保有が企業の経営戦略や市場価格にどのように影響を与えるかは非常に複雑なメカニズムが存在すると考えられるため、これらの実証分析を中心とした先行研究では結論は全くでない*4。特に図1に示すように、株式の売買が株主構成に変化を与え、それが企業の経営戦略および企業が市場価格に関わらず本源的にもつ価値(ファンダメンタル価格)を変化させ、それが株価を変化させ、それが株式の売買の判断を変えようという、ポジティブ・フィードバック過程が内在していることが分析を難しくしていると考えられる。実証研究のみではこのような、マイクロ・マクロ相互作用を含むメカニズムを分析することは困難である。また、取引参加者に占めるパッシブファンドの割合が現在ほど多かったことは過去

に形成されず資本の適切な配分機能が破壊され、社会にとって好ましくないという主張すらある [Fraser-Jenkins 16]。一方で、アクティブファンドへの批判も運用成績や手数料を中心になされている(例えば、[Bogle 14])。

*3 [Piketty 13] が主張した所得格差拡大の原因はこれとは異なる。

*4 実際、反論 [O'Brien 17, Rock 17] も多く、それらの反論に対する反論 [Elhauge 17] もある。

ないため、これ以上パッシブファンドが増えた場合の議論を実証研究だけで行うのは困難である。そもそも、どのような投資家がどのくらい存在するのかを測定すること自体容易ではない。価格形成や流動性にはさまざまな要因が複雑に関わっているため、実証分析では投資家の構成割合の変化が与える影響だけを取り出すことは困難である。

このような実社会におけるマイクロ・マクロ相互作用を含むメカニズムや、実社会でまだおきていない状況、および状況の変化の純粋な影響を議論するのにすぐれた手法として、コンピュータ上で仮想的にその状況を作り出し検証する、社会シミュレーションがある。社会シミュレーションは、例えば、自動車道の整備が交通渋滞へ与える影響分析や、テロや火災、伝染病が発生した場合の避難の方法やあるべき対策の分析などで、大きな成果をあげている^{*5}。

このような実際の金融市場におけるマイクロ・マクロ相互作用を含むメカニズムや、まだおきていない状況の変化の純粋な影響を議論するのにすぐれた手法として、コンピュータ上で仮想的にその状況を作り出し検証する、エージェントベースモデルの一種である人工市場モデルを用いたシミュレーションがある^{*6}。これまでの伝統的な経済学で使われてきた手法にはない強みがあるとして、Nature と Science に人工市場モデルに期待を寄せる論考が掲載されている [Farmer 09, Battiston 16]。そして人工市場モデルを用いたシミュレーション研究は、現実の金融市場の規制・制度変更の議論に貢献^{*7}したり、バブルや金融危機の発生メカニズムの解明に貢献したりした。

人工市場モデルは、架空の投資家であるエージェントと、架空の取引所である価格決定メカニズムから構成され、コンピュータ上で仮想的に金融市場をシミュレーションする。人工市場モデルを用いたシミュレーションでは、これまでにない投資家の分布が与える影響やまったく新しい規制の効果を議論できるうえ、その純粋な影響を抽出できる。これが人工市場シミュレーション研究の強みである。

人工市場モデルを用いてパッシブファンドを議論した研究もいくつかある。[水田 17a, Mizuta 17b, Mizuta 18e] は、パッシブファンドとは逆に値上がり期待できる銘柄を選別しそれらに投資する“アクティブファンド”は、売買の頻度が低かったとしても、まれに起きる市場が不安定になったときに比較的多く売買することにより市場の安定化・効率化に寄与していることを示し、パッシブファンドの増加は市場の不安定化・非効率化につながる恐れを指摘した。また、[高橋 11, Braun-Munzinger 16] は人工市場モデルを用いてパッシブファンドが市場価格へ与える影響を議論した。しかしながら、パッシブファンドによる水平株式保有が市場価格に与える影響を人工市場モデルを用いて議論した研究はない。

そこで本研究では、[水田 17a, Mizuta 17b, Mizuta 18e] が構築した人工市場モデルを2銘柄に拡張し、株式水平保有が経営戦略を変更させ企業間競争を阻害するモデルを加え、パッシブファンドの増加が企業間競争と市場価格へ与える影響を分析した。

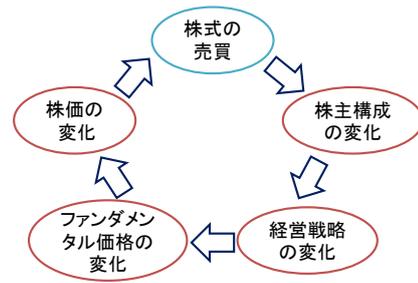


図 1: 水平株式保有におけるポジティブ・フィードバック過程

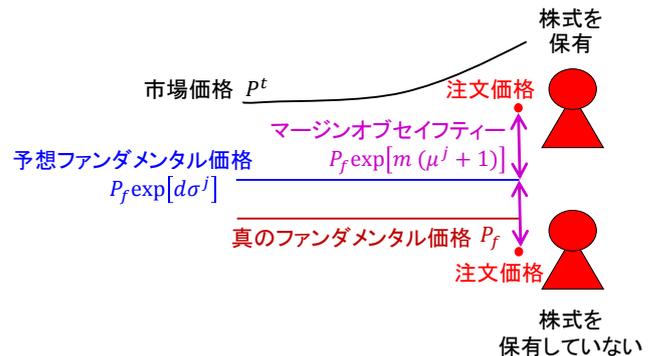


図 2: ファンダメンタルエージェントの注文価格

2. 人工市場モデル

本研究では、ファンダメンタル価格にもとづいて少ない機会にのみ売買を行う、現実市場で重要な投資家のモデル化に成功した [水田 17a, Mizuta 17b, Mizuta 18e] の人工市場モデルを2銘柄に拡張したモデルを用いる。モデル構築の基本理念は付録“モデル構築の基本理念”にて説明した。

2.1 エージェント

全エージェント数を N とする。初め、株式1と株式2の両方を1株ずつ保有、株式1のみ1株保有、株式2のみ1株保有、いずれの株式を保有しないエージェントが $N/4$ ずつ存在する。各エージェントは、1株保有している株式に対しては常に1株の売り注文を、保有していない株式に対しては常に1株の買い注文を出す。そのため、2株以上の保有、空売り（マイナスの保有株数）は発生しない。両銘柄の相互作用は後に述べる株主構成によるファンダメンタル価格の変化のみによって起き、各エージェントの注文価格の決定は各銘柄ごとに完全に行われる。

2.1.1 ファンダメンタルエージェント

ファンダメンタルエージェントは N_P 体存在する。時刻 t 、エージェント j の注文価格 $P_o^{t,j}$ は、

$$P_o^{t,j} = P_f \exp(d\sigma^j \pm m(\mu^j + 1)) \quad (1)$$

とする (図2も参照)。ここで、 d および m は定数であり、 σ^j は j ごとに異なる実数を出力する正規分布乱数、 μ^j は j ごとに異なる実数を出力する0から1までの一様乱数である。±は買い注文のときは−、売り注文のときは+をとる。

直近 (時刻 $t-1$) の市場価格 P^{t-1} に依存せず、株式がもつ本源的な価値 (ファンダメンタル価格 P_f) を元に注文価格

*5 例えば、[出口 09, 和泉 12] などが詳しい。

*6 優れたレビューとして、[LeBaron 06, Chen 12, 水田 14, Mizuta 16a, Todd 16, 和泉 17a, 和泉 17b] がある。

*7 人工市場モデルの金融市場の規制・制度の議論への貢献は [水田 14, Mizuta 16a, 和泉 17a] が詳しい。また、東京証券取引所の持ち株会社、日本取引所グループは人工市場モデルによる研究を“JPXワーキングペーパー” (<http://www.jpx.co.jp/corporate/research-study/working-paper/>) として多く公表している。

$P_o^{t,j}$ を決める。各エージェントはファンダメンタル価格 P_f を知らないが推定を試みている。そして、推定ファンダメンタル価格から十分安い価格で買おうとし、十分高い価格で売ろうとする傾向があるといわれ、この十分な価格差のことを安全マージン (Margin of Safety) とよぶ [Graham 03]。 $m(\mu^j + 1)$ は安全マージンの推定ファンダメンタル価格に対する比である。

2.1.2 テクニカルエージェント

テクニカルエージェントは N_T 体存在する。彼らは順張り戦略を採用する。時刻 t , エージェント j の注文価格 $P_o^{t,j}$ は、

$$P_o^{t,j} = P^t (P^t / P^{t-tm^j}) \quad (2)$$

とする。現実の金融市場の価格変動を再現するためにテクニカルエージェントが必要であることが知られている*8。

2.1.3 ノイズエージェント

ノイズエージェントは N_N 体存在し、時刻 t , エージェント j の注文価格 $P_o^{t,j}$ は、

$$P_o^{t,j} = P^t \exp(\eta \sigma^{t,j}) \quad (3)$$

とする。ここで η は定数、 $\sigma^{t,j}$ は t および j ごとに異なる実数を入力する正規分布乱数である。本研究では常に十分な量の取引が行われている株式を取り扱う。これまでに述べたエージェントだけだと注文価格が特定の価格付近に偏り売買があまり成立しないことが多く発生するので、ノイズエージェントを導入した。なお、実際の金融市場においてもこのような、流動性(多くの待機している注文がもたらす売買の成立のしやすさ)を供給する市場参加者が多く存在する。

2.2 価格決定メカニズム

時刻 t のすべてのエージェントの注文価格が決定されたのち、板寄せ方式 (call auction) [東証 15] で取引を成立させ各銘柄の市場価格 P^t を決定する。すなわち、買い注文は高い注文から、売り注文は安い注文から順番につき合わせていき、売買の注文価格が同じになったところを P^t とする。

2.3 ファンダメンタル価格の変更

Δt ごとに株主構成によっては両銘柄のファンダメンタル価格が変更になる。この変更が生じることを以後、“競争が起きた”とよぶ。 t が Δt で割り切れる時刻のみ競争が起きる。 $t - \Delta t$ から t までの各時刻において、株式 1 のみを保有するファンダメンタルエージェント数 n_1 , 株式 2 のみを保有するファンダメンタルエージェント数 n_2 , 両方を保有するファンダメンタルエージェント数 n_b を数え、 n_1, n_2, n_b のうち n_1 が最も大きい時刻が最も多ければ株式 1 のファンダメンタル価格を δP_f 増やし、株式 2 のそれを δP_f 減らす。 n_2 が最も大きい時刻が最も多ければその逆を行う。 n_b が最も大きい時刻が最も多ければファンダメンタル価格は変更されない(競争は起きない)。

このモデルは実際の以下の現象をモデル化したものである。片方の株式のみを保有する投資家は両企業が競争し保有する企業が競争に勝ちファンダメンタル価値が上昇することが自身の利益につながる。そのため、保有しないほうの企業に競争で勝つように保有している企業に働きかける。一方、両方の株式を保有している投資家は両企業が競争することによって、たとえ競争に勝った企業のファンダメンタル価格が上昇しても、競争に負けた方の企業も必ず保有しておりファンダメンタル価値の下落によって損失もこうむるので競争を促す動機がない。このような現象が近年大きな議論になっていることは“はじめに”で述べた通りである。

*8 例えば, [Chen 12]. 付録“モデルの妥当性”も参照。

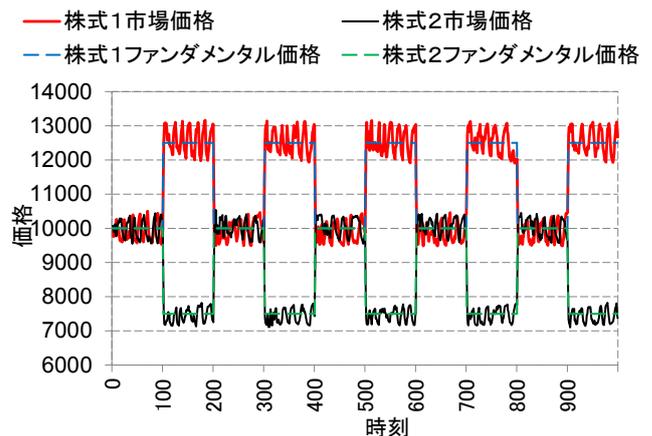


図 3: $N_{Fp} = 0$ のときの各株式の市場価格 P^t およびファンダメンタル価格 P_f の時系列

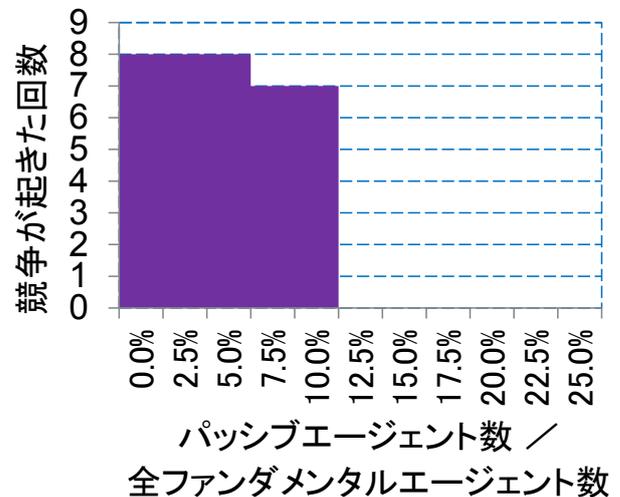


図 4: N_{Fp}/N_F ごとの競争が起きた回数

ファンダメンタルエージェントのみを対象としたのは、ファンダメンタルにもとづいた投資を行う投資家やパッシブファンド以外の投資家(投機家ともよばれる)は、企業と対話したり何かしらの経営戦略を働きかける(いわゆるエンゲージメント)を行わないことが多いことをモデル化したためである。

2.4 パッシブエージェント

ファンダメンタルエージェントの初期に両銘柄を保有している $N_F/4$ 体の内、 N_{Fp} 体はまったく取引を行わない。この取引を行わないファンダメンタルエージェントをパッシブエージェントとよぶ。“はじめに”で述べたとおり、近年、良い銘柄を組み入れるための売買を全く行わないパッシブファンドが増えており、これをモデル化した。

3. シミュレーション結果

各種パラメータは、 $N_F = 400, N_T = 100, N_N = 1000, P_f = 10000, d = 0.05, m = 0.02, tm_{max} = 100, \eta = 0.5, \Delta t = 100, \delta P_f = 2500$ とした。また、 $N_{Fp} = 0, 10, 20, 30, 40, 50, 60, 70, 80, 90, 100 = N_F/4$ に対してシミュ

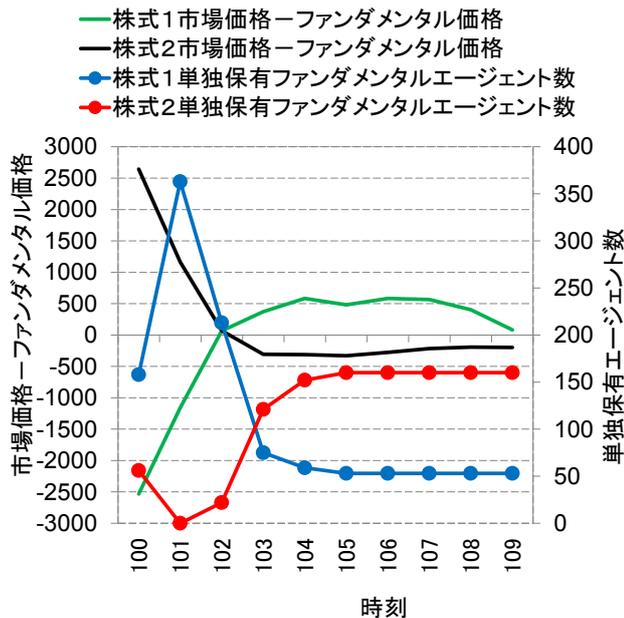


図 5: $N_{FP} = 0$ のときの各株式の市場価格とファンダメンタル価格の差 $P^t - P_f$ および単独保有ファンダメンタルエージェント数 n_1, n_2 の時系列 (時刻 $t = 100$ から 110 を拡大)

レーションを行い、各シミュレーションは $t = t_e = 1000$ まで行った。本モデルおよびこれらのパラメータの妥当性については付録“モデルの妥当性”で説明した。また、本モデルは他のモデルに比べパラメータが少なく、恣意性が入りにくいのが特徴である。

図 3 は $N_{FP} = 0$ のときの各株式の市場価格 P^t およびファンダメンタル価格 P_f の時系列である。ファンダメンタル価格の変更が頻繁に起きており、競争が頻繁に起きていることが分かる。しかも、2つの企業は交互に競争に勝っており、企業間競争のバランスをとるメカニズムが存在する可能性を示している。図 4 は N_{FP}/N_F ごとの競争が起きた回数である。 $N_{FP}/N_F > 12.5\%$ で競争が全く起きていない。パッシブファンドの割合がさほど大きくなって、競争を阻害する可能性を示している。

図 5 は $N_{FP} = 0$ のときの各株式の市場価格とファンダメンタル価格の差 $P^t - P_f$ および単独保有ファンダメンタルエージェント数 n_1, n_2 の時系列 (時刻 $t = 100$ から 110 を拡大) である。時刻 $t = 100$ で競争が発生し、株式 1 のファンダメンタル価格が上昇し、株式 2 のそれは下落した。ファンダメンタル価格が上昇した株式 1 では市場価格がそこに収束するまで買いが入り保有数が増えている。 $t = 102$ までに新しいファンダメンタル価格へ収束しているが、それ以後はオーバーシュート^{*9}してファンダメンタルより高い市場価格となっている。そのためこの期間は、株式 1 を保有しているファンダメンタルエージェント数の方が株式 2 のそれより少なくなっている。

つまり、現実においても、競争に勝った企業の市場価格が増加したファンダメンタル価格以上に上昇して割高となり競争を促す株主が離れて競争力を弱くする一方、競争に負けた企業の市場価格が減少したファンダメンタル価格よりさらに下落して

*9 オーバーシュートが実際に多く発生していることは実証研究で知られており、そのメカニズムに関しても人工市場モデルを用いて議論されている [Yagi 12b, 八木 12a, 水田 13, Mizuta 16b].

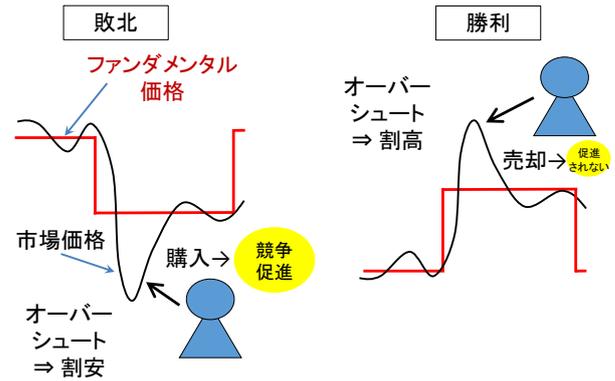


図 6: 企業間競争のバランスをとるメカニズム

割安となり競争を促す株主が増え競争力を強くして、企業間競争のバランスをとるメカニズムが存在する可能性があると考えられる。パッシブファンドの増加はこのようなメカニズムを弱める恐れがあると考えられる。

つまり、図 6 に示すように、競争に勝ちファンダメンタル価格が上昇すると一度はファンダメンタルエージェントの保有が増えるが、市場価格がオーバーシュートすることによりむしろ逆に保有が減り、競争を促す圧力はかえって少なくなる可能性を示している。逆に競争に負けた企業の方が、市場価格が下落したファンダメンタル価格よりもさらに下落して割安となり、ファンダメンタルエージェントの保有が増え、競争を促される可能性を示している。現実においても、競争に勝った企業の市場価格が増加したファンダメンタル価格以上に上昇して割高となり競争を促す株主が離れて競争力を弱くする一方、競争に負けた企業の市場価格が減少したファンダメンタル価格よりさらに下落して割安となり競争を促す株主が増え競争力を強くして、企業間競争のバランスをとるメカニズムが存在する可能性があると考えられる。パッシブファンドの増加はこのようなメカニズムを弱める恐れがあると考えられる。

4. まとめと今後の課題

本研究では、[水田 17a, Mizuta 17b, Mizuta 18e] が構築した人工市場モデルを 2 銘柄に拡張し、株式水平保有が経営戦略を変更させ企業間競争を阻害するモデルを加え、パッシブファンドの増加が企業間競争と市場価格へ与える影響を分析した。

その結果、パッシブファンドの割合がさほど大きくなって、競争を阻害する可能性を示した。また、競争に勝った企業の市場価格が増加したファンダメンタル価格以上に上昇して割高となり競争を促す株主が離れて競争力を弱くする一方、競争に負けた企業の市場価格が減少したファンダメンタル価格よりさらに下落して割安となり競争を促す株主が増え競争力を強くして、企業間競争のバランスをとるメカニズムが存在する可能性を示した。パッシブファンドの増加はこのようなメカニズムを弱める恐れがあると考えられる。

水平株式保有が与える影響の分析は、実証研究、人工市場研究ともにまだ始まったばかりであり、詳細な議論はこれからである。本研究のモデルにおいても、パッシブファンドへの資金流入の効果など無視した過程が多くあり、今後の課題である。

人工市場シミュレーションは投資家の分布の変化の純粋な効果を見ることができるよう、実現したことがない投資家の分布での分析もすることができる。ただその効果は確実な予想では

表 1: $N_{FP} = 100 = N_F/4$ の場合の株式 1 の各種統計量

リターンの標準偏差		1.25%
リターンの尖度		1.29
	ラグ	
二乗リターンの	1	0.22
自己相関係数	2	0.03
	3	-0.09

ない。さまざまなケースでのシミュレーションを行い、これまで予想されていなかった、“あり得る”メカニズムでの現象を見つけておくことが、人工市場シミュレーションの大きな役割であり、人工市場シミュレーションの限界である。そのため、さらなる詳細な議論では、実証分析など他の手法の結果と比較検討する必要がある。

付録

モデル構築の基本理念

人工市場シミュレーションを用いれば、これまでない投資家の分布が与える影響やまったく新しい規制の効果を議論できるうえ、その純粋な影響を抽出できる。これが人工市場シミュレーション研究の強みである。そして、多くの人工市場シミュレーション研究がこれまでない投資家の分布が与える影響や、規制・制度の変更を分析してきた [LeBaron 06, Chen 12, 水田 14, Mizuta 16a, Todd 16, 和泉 17a, 和泉 17b]。

ただその効果は確実な予想ではない。さまざまなケースでのシミュレーションを行い、これまで予想されていなかった、“あり得る”メカニズムでの現象を見つけておくことが、人工市場シミュレーションの大きな役割となる。金融市場でこれから実際におこる現象を定量的にも忠実に再現することが目的ではなく、規制や制度の変更が、どのようなメカニズムで価格形成に影響を与え、どのようなことが起こり得るのかという知識獲得が目的である。これは例えば実証分析など他の手法ではできないことである。

人工市場モデルは普遍的に存在するマクロ現象を再現すべきであると考えられる。人工市場シミュレーションでは、マクロ現象である市場価格のリターンや売買数量をモデル化しない。あくまで、投資家を模した“エージェント”と取引所を模した“価格決定メカニズム”といったマイクロメカニズムをモデル化し、そのマイクロメカニズムの相互作用の積み上げとしてマクロ現象が出力される。そのため、マイクロメカニズムのモデル化は現実の市場に即したものとし、結果として出力されるマクロ現象は、現実の市場で普遍的に存在するマクロ的性質を再現されるように作る必要がある。

しかし、普遍的ではなく特定の時期や資産、地域で出現するマクロ的性質すべてを再現することは本研究の目的ではない。必要以上に多くのマクロ的性質を一つのモデルで再現しようとすると、過剰に複雑なモデルをもたらす、関連する要素が多くなりすぎて、発生メカニズムの理解を妨げてしまう。

実際、複雑な人工市場モデルに対して、モデルが複雑になるとパラメータが増えモデルの評価が困難になるという批判がある [Chen 12]。モデルが複雑すぎると関連する要素が多くなりすぎて、発生メカニズムの理解を妨げてしまう。また、パラメータが増えるほどさまざまな出力がだせるようになり、モデルを作った人が導きたい結果へ恣意的に導くためのパラメータ

設定が行われる恐れがある。シンプルでパラメータが少ないモデルほど、パラメータ調整によって特定の結果に導くことが困難であるため評価が容易となる。

以上により、本研究では、分析目的を果たせる範囲内なるべくシンプルなモデルの構築を行っている。実際の市場を完全に再現することを目的としておらず、普遍的ではなく特定の時期や資産、地域で出現するマクロ的性質すべてを再現することや、実際には存在するであろう投資家をすべて網羅することはあえて行っていない。

[Weisberg 12] が述べているように、よいシミュレーションモデルとはその研究目的によって異なる。そのため、本研究のモデルは本研究の目的にのみおいてよいモデルであり、他の研究目的においてはよいモデルではない。また [Weisberg 12] が述べているように、数理モデルと異なり、シミュレーションモデルは投資家などのミクロの行動やその行動の理由と、市場価格などのマクロ現象との相互作用のメカニズムの解明ができることが強みである。数理モデルが強みとするマクロ現象の特徴分析や予測といったことは本研究の目的とせず、メカニズムの解明に焦点をあてている。

モデルの妥当性

人工市場モデルの妥当性は実証分析で得られている fat-tail や volatility-clustering といった代表的な stylized fact が再現できるかどうかで評価される [LeBaron 06, Chen 12, 水田 14, Mizuta 16a]。ファット・テールは、市場価格のリターンの分布が正規分布ではなく裾が厚い、すなわち、尖度が正であることである。ボラティリティ・クラスタリングは市場価格のリターンの 2 乗が、大きなラグでも自己相関係数が有意に正であることである。

[Sewell 11] など多くの研究で述べられているように、金融市場は不安定であり、安定的に、どのような時期にも有意に観測されるスタイライズド・ファクトはファット・テールとボラティリティ・クラスタリングの 2 つしかない。

しかも、これらは統計量の有意に正であることだけが安定して観測され、値そのものは、時期によって異なる。ファット・テールについては、実証分析でよく観測されるリターンの分布の尖度は 1 ~ 100 程度であり、ボラティリティ・クラスタリングについては、実証分析でよく観測されるリターンの自己相関は 0 ~ 0.2 程度と、かなりばらつきがある [Sewell 11]。

本研究のように、金融市場に共通する性質を分析対象とする人工市場が再現すべきは、これらの統計量が有意に正であり、問題ない範囲に値が収まっていることであって、特定の値に近づけることは本質的ではない。

表 1 は、 $N_{FP} = 100 = N_F/4$ の場合の株式 1 の毎期のリターン $\log(P^t/P^{t-1})$ の標準偏差と尖度、リターンの 2 乗の自己相関である。リターンの尖度がプラスで、ファット・テールが再現されている。また、リターンの 2 乗の自己相関もプラスで、ボラティリティ・クラスタリングが再現されていると考えられる。

留意事項

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

参考文献

[Azar 14] Azar, J., Schmalz, M. C., and Tecu, I.: Anti-Competitive Effects of Common Ownership, *SSRN*

- Working Paper Series* (2014),
<https://ssrn.com/abstract=2427345>
- [Battiston 16] Battiston, S., Farmer, J. D., Flache, A., Garlaschelli, D., Haldane, A. G., Heesterbeek, H., Hommes, C., Jaeger, C., May, R., and Scheffer, M.: Complexity theory and financial regulation, *Science*, Vol. 351, No. 6275, pp. 818–819 (2016),
<http://science.sciencemag.org/content/351/6275/818>
- [Bogle 14] Bogle, J. C.: The arithmetic of “all-in” investment expenses, *Financial Analysts Journal*, Vol. 70, No. 1, pp. 13–21 (2014),
<http://www.cfapubs.org/doi/pdf/10.2469/faj.v70.n1.1>
- [Braun-Munzinger 16] Braun-Munzinger, K., Liu, Z., and Turrell, A.: Staff Working Paper No. 592 An agent-based model of dynamics in corporate bond trading, *Bank of England, Staff Working Papers* (2016),
<http://www.bankofengland.co.uk/research/Pages/workingpapers/2016/swp592.aspx>
- [Chen 12] Chen, S.-H., Chang, C.-L., and Du, Y.-R.: Agent-based economic models and econometrics, *Knowledge Engineering Review*, Vol. 27, No. 2, pp. 187–219 (2012),
<http://dx.doi.org/10.1017/S0269888912000136>
- [出口 09] 出口 弘, 木嶋 恭一: エージェントベースの社会システム科学宣言—地球社会のリベラルアーツめざして, 勁草書房 (2009),
<http://www.keisoshobo.co.jp/book/b26210.html>
- [Elhauge 16] Elhauge, E.: Horizontal Shareholding, *Harvard Law Review*, Vol. 129, No. 5, p. 1267 (2016),
<https://harvardlawreview.org/?p=4185>
- [Elhauge 17] Elhauge, E.: The Growing Problem of Horizontal Shareholding, *SSRN Working Paper Series* (2017),
<http://ssrn.com/abstract=2988281>
- [Farmer 09] Farmer, J. D. and Foley, D.: The economy needs agent-based modelling, *Nature*, Vol. 460, No. 7256, pp. 685–686 (2009),
<https://www.nature.com/articles/460685a>
- [Fichtner 17] Fichtner, J., Heemskerk, E. M., and Garcia-Bernardo, J.: Hidden power of the Big Three? Passive index funds, re-concentration of corporate ownership, and new financial risk, *Business and Politics*, Vol. 19, No. 2, p. 298326 (2017),
<https://doi.org/10.1017/bap.2017.6>
- [Fraser-Jenkins 16] Fraser-Jenkins, I.: The Silent Road to Serfdom: Why Passive Investing is Worse Than Marxism, *Sanford C. Bernstein research report* (2016)
- [Graham 03] Graham, B. and Zweig, J.: *The Intelligent Investor: The Definitive Book on Value Investing*, Harper-Collins (2003)
- [和泉 12] 和泉 潔, 実世界とエージェントシミュレーション協同研究委員会: 実世界とエージェントシミュレーション, 電気学会 (2012),
http://www.bookpark.ne.jp/cm/ieej/detail.asp?content_id=IEEJ-GH1262-PRT
- [和泉 17a] 和泉 潔, 川久保 佐記, 米納 弘渡: 第 5 章 強靱な金融システム, 古田 一雄 (編), レジリエンス工学入門, 日科技連出版社 (2017),
<http://www.juse-p.co.jp/cgi-bin/html.pl5?i=ISBN978-4-8171-9624-8>
- [和泉 17b] 和泉 潔: 第 6 章 可能世界ブラウザとしてのエージェントシミュレーション, マルチエージェントのためのデータ解析 (マルチエージェントシリーズ), コロナ社 (2017),
<http://www.coronasha.co.jp/np/isbn/9784339028126/>
- [LeBaron 06] LeBaron, B.: Agent-based computational finance, *Handbook of computational economics*, Vol. 2, pp. 1187–1233 (2006),
[http://dx.doi.org/10.1016/S1574-0021\(05\)02024-1](http://dx.doi.org/10.1016/S1574-0021(05)02024-1)
- [水田 13] 水田 孝信, 和泉 潔, 八木 勲, 吉村 忍: 人工市場を用いた値幅制限・空売り規制・アップティックルールの検証と最適な制度の設計, 電気学会論文誌C (電子・情報・システム部門誌), Vol. 133, No. 9, pp. 1694–1700 (2013),
<http://doi.org/10.1541/ieejieiss.133.1694>
- [水田 14] 水田 孝信: 人工市場シミュレーションを用いた金融市場の規制・制度の分析, 博士論文, 東京大大学院工学系研究科 (2014),
<http://hdl.handle.net/2261/59875>
- [Mizuta 16a] Mizuta, T.: A Brief Review of Recent Artificial Market Simulation (Agent-Based Model) Studies for Financial Market Regulations and/or Rules, *SSRN Working Paper Series* (2016),
<http://ssrn.com/abstract=2710495>
- [Mizuta 16b] Mizuta, T., Kosugi, S., Kusumoto, T., Matsumoto, W., Izumi, K., Yagi, I., and Yoshimura, S.: Effects of Price Regulations and Dark Pools on Financial Market Stability: An Investigation by Multiagent Simulations, *Intelligent Systems in Accounting, Finance and Management*, Vol. 23, No. 1-2, pp. 97–120 (2016),
<http://dx.doi.org/10.1002/isaf.1374>
- [水田 17a] 水田 孝信, 堀江 貞之: 忍耐強い (Patient) アクティブ投資は市場を効率的にするのか?—人工市場によるシミュレーション分析—, 第 19 回金融情報学研究会, Vol. 19, (2017),
<http://sigfin.org/019-01/>
- [Mizuta 17b] Mizuta, T. and Horie, S.: Why do Active Funds that Trade Infrequently Make a Market more Efficient? - Investigation using Agent-Based Model, in *Computational Intelligence for Financial Engineering Economics (CIFER), 2017 IEEE Symposium Series on Computational Intelligence on* (2017),
<https://doi.org/10.1109/SSCI.2017.8280798>

- [水田 18a] 水田 孝信：パッシブファンドの新たな論点「水平株式保有」, スパークス・アセット・マネジメント (2018), <https://www.sparx.co.jp/report/special/2126.html>
- [水田 18b] 水田 孝信：水平株式保有するパッシブファンドの増加が企業間競争と市場価格へ与える影響—人工市場によるシミュレーション分析—, 第 32 回人工知能学会全国大会論文集人工知能学会 (2018), https://doi.org/10.11517/pjsai.JSAI2018.0_2J101
- [水田 18c] 水田 孝信：水平株式保有は経済発展をとめるのか?, スパークス・アセット・マネジメント (2018), <https://www.sparx.co.jp/report/special/2153.html>
- [Mizuta 18d] Mizuta, T.: Effect of Increasing Horizontal Shareholding with Index Funds on Competition and Market Prices – Investigation by Agent-Based Model –, in *2018 International Conference on Behavioral, Economic, Socio-cultural Computing (BESCom)* (2018), in press.
- [Mizuta 18e] Mizuta, T. and Horie, S.: Mechanism by which Active Funds Make Market Efficient Investigated with Agent-Based Model, *Evolutionary and Institutional Economics Review* (2018), <https://doi.org/10.1007/s40844-018-0102-0>
FULL Text: <https://rdcu.be/7mVh>
- [O'Brien 17] O'Brien, D. and Waehrer, K.: A The Competitive Effects of Common Ownership: We Know Less than We Think, *SSRN Working Paper Series* (2017), <http://ssrn.com/abstract=2922677>
- [Piketty 13] Piketty, T.: *Le Capital au XXI^e siècle*, Éditions du Seuil (2013), (邦訳: 山形浩生, 守岡桜, 森本正史: 21 世紀の資本, みすず書房 (2014))
<https://www.msz.co.jp/book/detail/07876.html>
- [Rock 17] Rock, E. and Rubinfeld, D.: Defusing the Antitrust Threat to Institutional Investor Involvement in Corporate Governance, *SSRN Working Paper Series* (2017), <http://ssrn.com/abstract=2925855>
- [Sewell 11] Sewell, M.: Characterization of financial time series, *Research Note, University College London, Department of Computer Science*, No. RN/11/01 (2011), <http://finance.martinsewell.com/stylized-facts/>
- [高橋 11] 高橋 大志：社会シミュレーションによる金融市場分析, 横幹連合コンファレンス予稿集, Vol. 2011, pp. 69–69 (2011), <http://doi.org/10.11487/oukan.2011.0.69.0>
- [Todd 16] Todd, A., Beling, P., Scherer, W., and Yang, S. Y.: Agent-based financial markets: A review of the methodology and domain, in *Computational Intelligence for Financial Engineering Economics (CIFER), 2016 IEEE Symposium Series on Computational Intelligence on* (2016), <https://doi.org/10.1109/SSCI.2016.7850016>
- [東証 15] 東証：東証公式 株式サポーター 株式取引編, 東京証券取引所 (2015), <http://www.jpx.co.jp/learning/tour/books-brochures/detail/08.html>
- [Weisberg 12] Weisberg, M.: *Simulation and Similarity: Using Models to Understand the World*, Oxford Studies in the Philosophy of Science (2012), (邦訳: 松王政浩: 科学とモデル-シミュレーションの哲学 入門-, 名古屋大学出版会 (2017))
<http://www.unp.or.jp/ISBN/ISBN978-4-8158-0872-3.html>
- [Wurgler 10] Wurgler, J.: On the Economic Consequences of Index-Linked Investing, Working Paper 16376, National Bureau of Economic Research (2010), <http://www.nber.org/papers/w16376>
- [八木 12a] 八木 勲, 水田 孝信, 和泉 潔：人工市場を用いた市場暴落後における反発メカニズムの分析, 情報処理学会論文誌, Vol. 53, No. 11, pp. 2388–2398 (2012), <http://id.nii.ac.jp/1001/00087035/>
- [Yagi 12b] Yagi, I., Mizuta, T., and Izumi, K.: A study on the reversal mechanism for large stock price declines using artificial markets, in *2012 IEEE Conference on Computational Intelligence for Financial Engineering Economics (CIFER)*, pp. 1–7 (2012), <http://dx.doi.org/10.1109/CIFER.2012.6327791>

人工市場を用いた分散投資規制が市場に与える影響分析 ～ファンダメンタル価格急落時と急騰時における比較～

Analysis of the Market Impact of the Rule for Investment Diversification at the Time of a Crashing Market and a Soaring Market using a Multi-Agent Simulation

丸山隼矢^{1*} 水田孝信² 八木勲³
Maruyama Shunya¹ Mizuta Takanobu² Yagi Isao³

¹ 神奈川工科大学大学院工学研究科情報工学専攻

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

² スパークス・アセット・マネジメント株式会社

² SPARX Asset Management Co., Ltd.

³ 神奈川工科大学情報学部情報工学科

³ Faculty of Information Technology, Kanagawa Institute of Technology

Abstract: In recent years the risk of mutual funds has become difficult to assess. This is because mutual funds have come to choose various assets, some of which may have high risk, and there may be some funds whose performances depend on dangerously much those of a part of the assets that the funds hold, and so on. Companies managing mutual funds are expected to perform risk control to prevent investors from taking unforeseen risk of funds. A related revision to the investment fund legal system in Japan led to establishing what is known as “the rule for investment diversification.” Some papers discussed that the rule for investment diversification affected price formation at the time of a market crash; however, we could not find that it affects price formation at the time of a soaring market. In this paper, we investigated that the rule for investment diversification affected price formation in financial markets where two types of investors who followed the rule and did not follow it participated at the time of a soaring (crashing) market that was caused by the bulge (collapse) of an asset fundamental price using agent-based simulations and discussed the difference between these effects. As results, we found that, in two-asset markets where two types of investors who followed the rule and did not follow it participated, when one asset fundamental price soared, the rule for investment diversification prevented its price rising, and when one asset fundamental price collapsed, the rule promoted the other’s price to decline.

1 はじめに

投資信託（以下、投信と記す）とは、投資家から集めた資金をまとめ、資産運用の専門家が株式や債券などに投資する金融商品である。投信は利益を追求するためにさまざまな資産を組み入れ対象とする場合がある。中にはその仕組みが複雑なためリスクの大きさが把握しにくい金融商品も含まれており、それらを入れる投信はリスクが把握しにくくなっている。投信

を購入する投資家がそれらのリスクをすべては把握することは事実上不可能である。そのため、投資家が想定外のリスクを負うことを未然に防ぐため、投信の運用会社側でリスクをコントロールすることが求められるようになった。その結果、2013年には投資信託法制が改正され、2014年12月より分散投資規制という規制が設けられることとなった[蒲谷 14, 杉田 14]¹。

分散投資規制は投信の各構成資産に対して保有上限を設ける規制である。分散投資そのものの是非につ

*連絡先：神奈川工科大学大学院工学研究科情報工学専攻
〒 243-0292 神奈川県厚木市下荻野 1030
E-mail: s1885023@cce.kanagawa-it.ac.jp

¹欧州では同様の規制が既にも実施されている [The European Parliament and of the Council 09]。

いては、主に運用成績のよし悪しの観点から多くの実証研究で議論されている。Cremer et al.[Cremer 09] は、高いアクティブシェア²の投信は、ベンチマークインデックスの投信より運用成績が総じてよいのに対し、低いアクティブシェアの投信は運用成績がよくないことを明らかにした。また低い手数料の高アクティブシェアの投信はインデックス投信より投資家にアルファ³を与えることを示した [Cremer 16]。Petajisto[Petajisto 13] は、高アクティブシェアかつ低ボラティリティの投信を扱う投資家の運用成績は、低アクティブシェアかつ低ボラティリティの投信を扱う投資家の運用成績よりよいことを示している。

このように実証研究では分散投資に関する運用成績についての議論は盛んに行われているが、分散投資に何らかの制約（分散投資規制等）が設けられたときの市場価格形成についての議論は行われていない。なぜなら、現実の市場には、さまざまな投資家が取引に参加しているため、分散投資の制約による取引のみが価格形成に与える影響を抽出することは困難だからである。

特定の取引が市場に与える影響を分析するような課題、つまり、実証研究では議論が困難な課題を分析する方法の1つとして、人工市場を用いる方法がある。人工市場とは、コンピュータ上に仮想的に構築されたマルチエージェントシステムの金融市場である [Chiarella 09, Chen 12, Yeh 13]。人工市場では、エージェントにそれぞれ独自の売買手法を与え、それらを投資家として金融資産の取引をさせると、市場がどのような振る舞いをするかを確認することができる。その一方で、市場側に何らかの制約（市場安定化や効率化のための制度等）をモデル化し組み込むことで、投資家がどのように振る舞うか、さらに、彼らの振る舞いによって市場にどのような影響が現れるかを検討することも可能となる。

最近では人工市場を用いて市場規制制度が金融市場に与える本質的な影響を分析する研究が盛んに行われている [Yagi 10, Yeh 13, Mizuta 15, Zhou 17]。

分散投資規制に関しては下記の研究が行われている。Yagi et al.[Yagi 17] は、2資産人工市場を用いて、一方のファンダメンタル価格が急落したときに他方の資産の価格形成に与える影響を調査し、分散投資規制が適用されている場合は他方の資産価格も連動して下落することを明らかにしている。Nozaki et al.[Nozaki 17] は、3資産人工市場においては、ある資産のファンダメンタル価格が急落すると、連動して価格下落する資産が存在する一方で、価格下落した資産から回収された資金による需要が集中することで価格が上昇する資産

が現れることも確認した。

このように、人工市場を用いて分散投資規制がファンダメンタル価格が急落したときの価格形成に与える影響は議論されてきた。しかし、一方で金融市場が活況となったときに分散投資規制が市場に与える影響を調査することも肝要である。

そこで、本研究では人工市場を用いて、分散投資規制がファンダメンタル価格が急騰したときの価格形成に与える影響について調査した。そして、ファンダメンタル価格急落時の価格形成と比較し、どのような違いがみられるか議論する。まず2節では、本研究にて使用する人工市場モデルを提案する。3節では、前節で提案した人工市場を用いてファンダメンタル価格が急騰するときと急落するときの各資産の価格推移を確認する。4節では前節で得られた結果から考察を行う。5節にはまとめと今後の課題を記す。

2 人工市場モデル

本研究では、水田らの人工市場モデル [Mizuta 15] を基にして、人工市場を2資産市場へと拡張し、分散投資規制モデルを構築した。

2.1 注文プロセス

本モデルは2つのリスク資産（以下、単に「資産」と呼ぶ）のみを取引対象とし、価格決定メカニズムは連続ダブルオークション方式（ザラバ方式）とした。本市場には n 体のエージェントが取引に参加する。エージェントはエージェント番号 $j = 1$ から順番に $j = 2, 3, 4, \dots$ と注文を出す。最後のエージェント $j = n$ が注文を出すと、次の時刻にはまた初めのエージェント $j = 1$ から注文を出し繰り返される。時刻 t は1体のエージェントが注文を出すごとに1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。

エージェント j は注文価格、売り買いの別を以下のように決める。時刻 t にエージェント j が予想する価格の変化率（予想リターン） $r_{e_j,k}^t$ は、以下の式1から得られる。

$$r_{e_j,k}^t = \frac{1}{w_{1,j,k}^t + w_{2,j,k}^t + u_{j,k}^t} (w_{1,j,k}^t r_{e_{1,j,k}}^{t-1} + w_{2,j,k}^t r_{e_{2,j,k}}^{t-1} + u_{j,k}^t \epsilon_{j,k}^t) \quad (1)$$

ここで、 $w_{i,j,k}^t$ は時刻 t 、エージェント j 、資産 k の i 項目の重みであり、シミュレーション開始時に、それぞれ0から $w_{i,max}$ まで一様乱数で決める。この値は後述する学習過程により変化する。 $u_{j,k}$ はエージェント j 、資産 k の3項目の重みであり、シミュレーション開始

²アクティブシェアとは、投信がアクティブ運用されている度合いを表す指標で、投資先を集中させると上昇し、分散させると減少する。

³アルファとは、市場の平均運用成績を上回る運用成果のことを指す。

時に、それぞれ0から u_{max} まで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。

$r_{e_{1,j,k}}^t$ は、時刻 t におけるエージェント j の資産 k に対するファンダメンタル投資家成分だけの場合の予想リターンで $r_{e_{1,j,k}}^t = \log(P_{f_k}^t/P_k^t)$ 、同様に $r_{e_{2,j,k}}^t$ はテクニカル投資家成分だけの場合の予想リターンで、 $r_{e_{2,j,k}}^t = \log(P_k^t/P_k^{t-\tau_j})$ である ($k = 1, 2$)。 $P_{f_k}^t$ は時間によらず一定の資産 k のファンダメンタル価格である。ファンダメンタル価格とは、金融資産を発行する企業自体が持っている実態の価値に基づいた価格を指す。 P_k^t は資産 k の時刻 t での取引価格（取引されなかった時刻では一番最近に取引された価格であり、時刻 $t = 0$ では $P_k^t = P_{f_k}$ とする）である。 τ_j は1から τ_{max} まで一様乱数でエージェントごとに決める。 $\epsilon_{j,k}^t$ は時刻 t 、エージェント j 、資産 k の乱数項で、平均0、標準偏差 σ_e の正規分布乱数である。

式1の右辺の括弧内の第1項目は、ファンダメンタル価格と比較して、安ければプラスの予想リターンを、高ければマイナスの予想リターンを示すファンダメンタル投資家の成分である。なお、ファンダメンタル投資家は通常ファンダメンタル価値を参照して投資判断を行う投資家を指す。第2項目は過去のリターンがプラス（マイナス）であるならプラス（マイナス）の予想リターンを示す、テクニカル投資家の成分である。テクニカル投資家は過去の価格推移を参照して投資判断を行う投資家を指す。第3項目はノイズを表している。

予想価格 $P_{e_{j,k}}^t$ は、予想リターン $r_{e_{j,k}}^t$ に基づいて式2から求められる⁴。

$$P_{e_{j,k}}^t = P_k^{t-1} \exp(r_{e_{j,k}}^{t-1}) \quad (2)$$

注文価格 $P_{o_{j,k}}^t$ は $P_{e_{j,k}}^t - P_d$ から $P_{e_{j,k}}^t + P_d$ までの一様乱数で決める。ここで、 P_d は定数である。価格の変化幅の最小単位は δP とし、注文の売り買いは予想価格 $P_{e_{j,k}}^t$ と注文価格 $P_{o_{j,k}}^t$ の大小関係で式3のように決まる。

$$\begin{aligned} P_{e_{j,k}}^t > P_{o_{j,k}}^t &\text{なら買い} \\ P_{e_{j,k}}^t < P_{o_{j,k}}^t &\text{なら売り} \end{aligned} \quad (3)$$

注文数は常に1と一定とする。

全てのエージェントは、注文価格や注文数を決定後、レバレッジ制約に違反していないか判定を行う。さらに分散投資規制対象エージェントはその判定も行う。レバレッジ制約と分散投資規制の詳細は2.3節で説明する。

本モデルの価格決定メカニズムはザラバ方式であるため、買い（売り）注文は、その注文価格より安い（高

い）売り（買い）注文が市場に既に存在すれば、その中で最も安い（高い）売り（買い）注文と即座に取引が成立する。しかし、相対する注文が市場になければ、今回の注文は市場に残す。市場に残した注文は、キャンセル時間 t_c だけ経過しても取引が成立しなかったときキャンセルされる。

2.2 学習プロセス

本研究では、実証研究 [Yamamoto 13] が存在を示している「投資戦略の切り替え」に焦点をあて、そのメカニズムの分析を行いやすいように比較的シンプルでパラメータの少ないモデルの構築を行った。戦略を状況に応じて切り替えるという学習プロセスを以下のようにモデル化した。すなわち、価格変化の方向を当てている戦略のウエイトを引き上げ、外れている戦略のウエイトを引き下げたようにした。また、資産 k の学習期間のリターン $r_{i,k}^t$ をかけることにより、小さい価格変動を当てたり外したりしても大きくウエイトが増減しないようにした。学習はエージェントごとに、各エージェントが注文を出す直前に行われる。これらの予想リターン $r_{e_{i,j,k}}^t$ が資産 k の学習期間のリターン $r_{i,k}^t = \log(P_k^{t-1}/P_k^{t-t_i})$ と比べ、同符号なら、 $w_{i,j,k}^t$ を $w_{i,j,k}^{t-1} + k_l |r_{i,k}^t| p_j^t (w_{i,max} - w_{i,j,k}^{t-1})$ に、異符号なら、 $w_{i,j,k}^t$ を $w_{i,j,k}^{t-1} - k_l |r_{i,k}^t| p_j^t w_{i,j,k}^{t-1}$ に更新する。ここで、 k_l は定数、 p_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。

上記学習プロセスの他に、小さい確率 m で $w_{i,j,k}^t$ を再設定する。つまり、0から $w_{i,max}$ までの一様乱数で決めなおす。これはランダム学習を意味しており、実績からの学習と組み合わせることにより、エージェントが試行錯誤的により良い戦略のウエイトを求める姿を客観的にモデル化している。

2.3 制度モデル

本モデルは、水田ら [Mizuta 15] では実装されていないが、資産の総保有量を制限するレバレッジ制約と、各資産の保有量を制限する分散投資規制から構成される。既述のようにレバレッジ制約はすべてのエージェントが対象であるが、分散投資規制は該当するエージェントのみが対象となる。

本モデルにおいて、レバレッジ制約は、各エージェントの資産の取引高の総額を、純資産以下に規制するようにモデル化した⁵。レバレッジ制約は以下の式で表

⁴本研究では対数リターンを使用している。そのため予想リターンは現在の価格の対数と予想価格の対数の差である。すなわち、 $r_{e_{j,k}}^t = \log P_{e_{j,k}}^t - \log P_k^t = \log P_{e_{j,k}}^t / P_k^t$ であり、これより式2が導き出される。

⁵通常の株式投資を行う投信の場合、投資資金の借入れができないため、仕組み上、レバレッジ比率が1より大きい投資はできない。よって、本制約は外部からの規制という意味合いではなく、投信の特性を表したものである。

される。

$$\sum_{k=1}^2 |P_k^t S_{j,k}^t| \leq NAV_j^t \quad (4)$$

ここで、 $S_{j,k}^t$ は、時刻 t におけるエージェント j の資産 k の保有量であり、 $S_{j,k}^t > 0$ なら買い保有している状態、 $S_{j,k}^t < 0$ なら空売りしている状態を表している。

なお、時刻 t におけるエージェント j のキャッシュの保有量を C_j^t とすると、エージェント j の純資産 NAV_j^t は次のように定義される。

$$NAV_j^t = \sum_{k=1}^2 P_k^t S_{j,k}^t + C_j^t \quad (5)$$

$$\frac{|P_k^t S_{j,k}^t|}{NAV_j^t} \leq w_{dir} \quad (6)$$

w_{dir} は、分散投資規制の規制比率（以降、規制比率と略す）であり、各エージェントの純資産に対する各資産の保有高の上限率である。

何らかの理由（例えば、 P_k^t が P_k^{t-1} より大きく上昇した等）で式 6 が満たさなくなったとき、エージェントは式 6 を満たすようになるまで資産 k の注文を出しつづけるようにしている。このような売買にした理由は次のとおりである。現実世界では、ある投信構成資産が上限を超えた場合、1 か月以内に上限を超えないよう資産量を減らさなければ違法となってしまう。そのため投信運用者はその資産の保有量を上限を超えなくなるまで減らし続けるからである。規制違反を解消するため時に強制的に発注される売り（買い）注文のことを、「規制違反売り（買い）注文」と呼ぶ。

これらの注文は資産保有量を減らすことが目的であるため、損益度外視で発注することになる。よって、予めそのような事態になることを防ぐため、分散投資規制が適用されたエージェントは、注文を発注する際にその注文が規制に違反しそうな場合（上記の式 6 を満たさない場合）は、それをキャンセルするよう振る舞うようにした。

3 シミュレーション結果と考察

水田ら [Mizuta 13] は、様々なパラメータを検討し 3.1 節で述べる妥当性検証を行った結果、後述するパラメータ値を妥当性の高い値として用いている。よって、本研究でも同様のパラメータを用いる。具体的には、パラメータを以下のように設定した。 $n = 1,000$, $k = 2$, $w_{1,max} = 1$, $w_{2,max} = 10$, $u_{max} = 1$, $\tau_{max} = 10,000$, $\sigma_e = 0.03$, $P_d = 1,000$, $t_c = 10,000$, $t_l = 10,000$, $k_l = 4$, $m = 0.01$, $\delta P = 1$, $w_{dir} = 0.5$, $C_j^0 = 40,000$,

表 1: $n_r_ratio = 50\%$ 条件下におけるスタイライズド・ファクト

	急騰		急落	
	資産 1	資産 2	資産 1	資産 2
尖度	54.77	5.30	7.25	19.72
ラグ				
1	0.12	0.09	0.16	0.22
リターンの				
2 乗の	0.10	0.07	0.14	0.18
3	0.10	0.06	0.13	0.12
自己相関				
4	0.14	0.05	0.12	0.07
5	0.26	0.03	0.11	0.07

$S_{j,k}^0 = 48$, $NAV_j^0 = 1,000,000$ とした。シミュレーション期間 t は 1,000,000 とする。

本研究では、1) ファンダメンタル価格が急騰したとき ($P_{f_2} = 10,000$, 時刻 $t = 0$ から $t = 100,000$ までは $P_{f_1} = 10,000$, $t = 100,001$ 以降は $P_{f_1} = 13,000$)、2) ファンダメンタル価格が急落したとき ($P_{f_2} = 10,000$, 時刻 $t = 0$ から $t = 100,000$ までは $P_{f_1} = 10,000$, $t = 100,001$ 以降は $P_{f_1} = 7,000$) についてシミュレーションを行う。それぞれの場合で、すべてのエージェントに対する、分散投資規制が適用されるエージェント⁶（以下、「規制あり」エージェントと呼ぶ）の割合を変化させる。すべてのエージェントに対する規制ありエージェントの割合を n_r_ratio とし、 n_r_ratio が 0%, 10%, 50%, 90%, 100% の 5 パターンでシミュレーションを行う。シミュレーションは各条件の下でそれぞれ 30 回ずつ試行し、その結果をもとに議論を行った。ただし、3.1 節のスタイライズド・ファクトについては 30 回試行の平均を、3.2 節以降の議論は各シミュレーション条件の下で高い確率で発現した特徴的な結果の 1 つを抽出して行っている。

3.1 人工市場モデルの妥当性

現実の市場ではファット・テイルとボラティリティ・クラスタリングが現れる、と多くの実証研究で指摘されている [Sewell 06, Cont 01]。ファット・テイルは、資産価格のリターンの分布が厚い、すなわち、尖度が正であることである。また、ボラティリティ・クラスタリングは資産価格のリターンの 2 乗が、ラグが増えても自己相関係数が有意に正であり、長期記憶性を持つことである。

本提案モデルにおいてもファット・テイルとボラティリティ・クラスタリングが再現されているか確認を行った。その結果、すべての条件下においてこれらが再現さ

⁶厳密には分散投資規制が適用されるのは投信構成資産であり、投信運用者ではない。しかし本論文では便宜上エージェントに対して規制が適用されているか否かで記す。

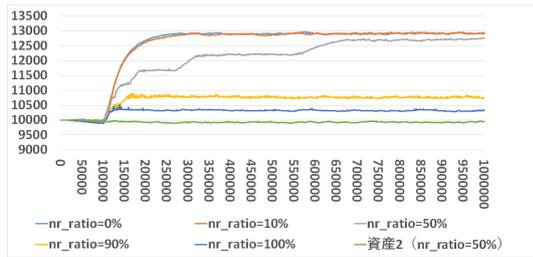


図 1: 資産 1 のファンダメンタル価格が急騰したときの資産 1 ($n_r_ratio=0\%$, 10% , 50% , 90% , 100%) と資産 2 ($n_r_ratio=50\%$) 価格推移

れることが確認できた。一例として、 n_r_ratio が 50% のとき、かつ、ファンダメンタル価格が急騰するときと急落するときのスタイルズド・ファクトを表 1 に記す。この表からもわかるように、尖度とリターンの 2 乗の自己相関ともに正值となっている。なお、スタイルズド・ファクトはすべて 100 ステップ間隔での価格を用いて計算した。なぜならば、本モデルの時刻は注文をただけで取引が成立しない場合も時刻が進むため、時刻 1 ごとの全ての価格を用いたスタイルズド・ファクトでは、多くの価格変動がないデータによるバイアスがかかってしまうからである。

3.2 ファンダメンタル価格急騰時

本節では、片方の資産（資産 1）のファンダメンタル価格のみが急騰した場合についての価格形成についての分析を行った。ファンダメンタル価格は、100,000 期までは 10,000 とし、100,001 期に 13,000 に変化させる。

各パターンの価格推移を図 1 に示す。（ただし、資産 2 の価格はどのパターンでも同じような価格推移であったため、ここでは $n_r_ratio = 50\%$ の時のみを示す。）

図 1 より、資産 1 のファンダメンタル価格が急騰すると、 n_r_ratio がいずれの場合であっても、資産 1 の資産価格は上昇することがわかる。しかし、 n_r_ratio が増えるごとに資産価格が収束する値が低くなり、ファンダメンタル価格まで到達しないことが確認できる。また $n_r_ratio = 50\%$ など規制ありエージェント数と規制なしエージェント数にそれほど差がないときは資産 1 の価格は段階的に資産価格が上昇することが確認できる。

資産 1 の資産価格が上昇した理由としては、資産 1 のファンダメンタル価格急騰に伴い、資産 1 の買い注文が売り注文に対して大きく増加したためだと考えられる。また、 n_r_ratio が増加するにつれ資産 1 の価格が上昇しなくなる理由としては、市場内に規制ありエージェントが存在する割合が増えると、規制による買い注文のキャンセル数が増加し、その結果買い注文の取

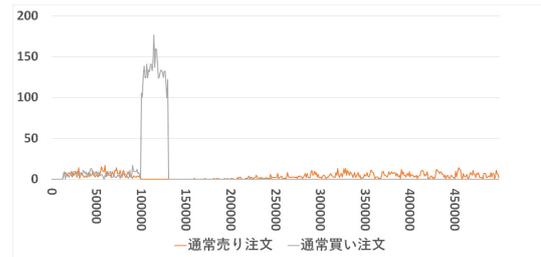


図 2: $n_r_ratio=0\%$ のときの資産 1 の注文種別ごとの取引成立数

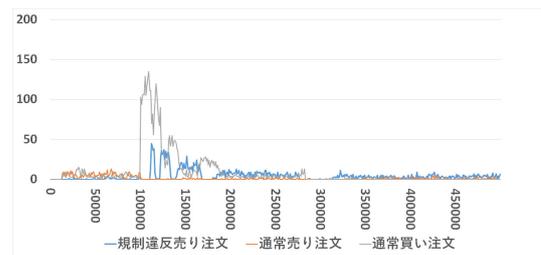


図 3: $n_r_ratio=50\%$ のときの資産 1 の注文種別ごとの取引成立数

引成立数が減少し、価格上昇力が弱まるためだと考えられる。

以上の仮説を検証するため、資産 1 における注文種別ごとの取引成立数について調査した。その結果を、図 2,3,4 に示す。図 2,3,4 から、資産 1 のファンダメンタル価格が急騰した後（100,000 期以降）、買い注文の取引成立数が他の注文に比べて多いことが確認できる。また n_r_ratio が増えるにつれ買い注文の取引成立数が減っていることも確認できる⁷。

また、 n_r_ratio が 50% の時に、資産 1 の価格が段階的に上昇する原因としては、規制違反時に発生する買い注文のキャンセル数と規制違反売り注文数の多寡が原因だと考えられる。買い注文のキャンセル数の推移を図 5 に示す。

図 1,5 より、資産 1 の価格が上昇するにしたがって、買い注文のキャンセル数も増加し（例えば、250,000 期から 300,000 期前後）、価格上昇が止まり安定期に入ると、買い注文のキャンセル数は漸減している（例えば、300,000 期から 550,000 期前後）ことが確認できる。

以下、このような現象が発生する理由を述べる。ファンダメンタル価格が上昇するとそれに合わせて資産 1 の取引価格も上昇しはじめる。すると分散投資規制に違反するエージェントが現れはじめ、資産 1 に対する

⁷図 2 以降における注文は各期に発注した注文種別ごとの注文数であり、これらと相対する注文は、以前注文されたが取引が成立せずに市場に留まっている注文である。そのため、グラフ上の各期の売り注文数と買い注文数は必ずしも一致するわけではない。

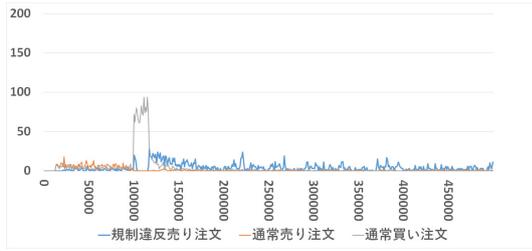


図 4: $n_r_ratio=100\%$ のときの資産 1 の注文種別ごとの取引成立数

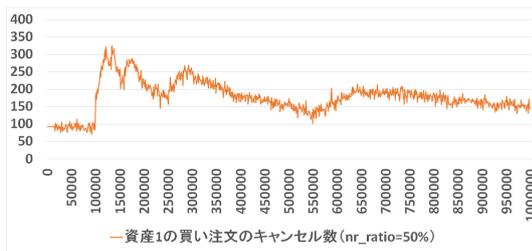


図 5: $n_r_ratio=50\%$ のときの資産 1 への買い注文キャンセル数

買い注文キャンセルと規制違反売り注文が現れるようになる (図 6 右). 仮に違反状態が解消されたとしても, 資産 1 の保有高は高い状態がつづくため新たに追加購入すると再び規制違反となる. よって, 新たに買い注文が発注されようとしてもキャンセルされるので, 買い注文のキャンセル数が急増する. これにより, それまで買い注文の方が多かった状態から需給バランスが均衡する状態へと移ることで, 資産 1 の価格上昇が止まり, 価格推移が横ばいへと移行する. その後, 規制違反売りではない通常の売り注文により, 各エージェントの資産 1 の保有高が下がってくると, 規制違反売り注文および買い注文のキャンセルも減少する. すると投資戦略のファンダメンタル成分の影響により, 再び買い注文が増加し価格が上昇しはじめる. 以上のプロセスが繰り返し起こることで段階的な価格上昇が発生していると考えられる.

3.3 ファンダメンタル価格急落時

本節では, 片方の資産 (資産 1) のファンダメンタル価格のみが急落した場合について分析を行った. ファンダメンタル価格は, 100,000 期までは 10,000 とし, 100,001 期に 7,000 に変化させる. Yagi et al.[Yagi 17] も一方の資産のファンダメンタル価格が急落したときの調査をおこなっているが, 規制ありエージェントのみが取引に参加したケース ($n_r_ratio=100\%$) のみ調査

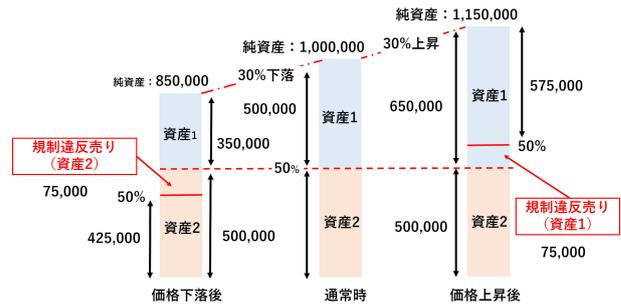


図 6: 資産価格上昇および下落時に規制違反注文を出すまでのメカニズム

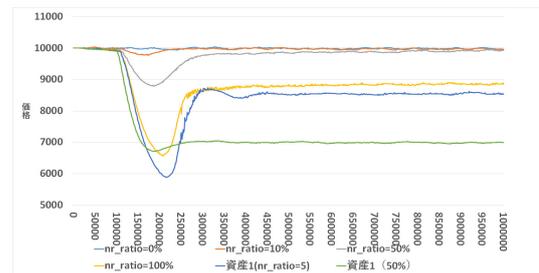


図 7: 資産 1 のファンダメンタル価格が急落したときの資産 2 ($n_r_ratio=0\%, 10\%, 50\%, 90\%, 100\%$) と資産 1 ($n_r_ratio=50\%$) 価格推移

していた. 本研究では, そのほかのケースも調査した. 各パターンでの価格推移を図 7 に示す. (ただし, 資産 1 の価格はどのパターンでも同じような価格推移であったため, ここでは $n_r_ratio=50\%$ の時のみを示す.)

図 7 より資産 1 の下落に伴い資産 2 の資産価格が連動して下落していることが分かる. また, n_r_ratio が 50% を超えると, 資産価格の下落の幅が大きくなること分かる.

資産 2 の価格が連動して下落した理由は以下のように考えられる. まず, 資産 1 のファンダメンタル価格が急落するに伴い, 資産 1 の資産価格も急落する. するとエージェントの純資産が小さくなると同時に, 資産 2 の保有高が相対的に高くなり規制違反状態となる (図 6 左). その結果, 数多くの規制ありエージェントから規制違反売り注文が発注され, 資産 2 の資産価格が下落する.

以上の仮説を調査するため, 資産 2 における注文種別ごとの取引成立数について調査した. その結果を, 図 8 に示す. 図 8 より, ファンダメンタル価格が急落した直後 (100,000 期), 規制違反売り注文が増加していることが確認できる.

また, n_r_ratio が増加するにつれ, 資産 2 の資産価格の下落幅が大きくなる理由は, 以下のように考えら

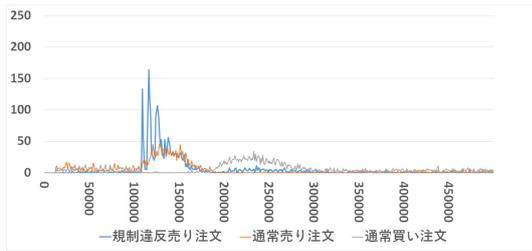


図 8: $n_r_ratio=50\%$ のときの資産 2 の注文種別ごとの取引成立数

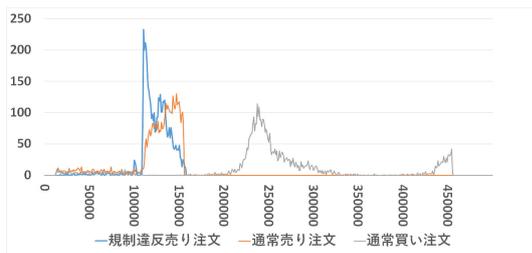


図 9: $n_r_ratio = 100\%$ のときの資産 2 の注文種別ごとの取引成立数

れる。まず、上記で説明した通り規制違反売り注文が発注されることで資産価格が下落する。規制ありエージェントの割合が多いほど、規制違反売り注文数も多くなる（図 8、図 9）ので、資産価格下落トレンドが一方方向に長く続くようになる。すると、エージェントの注文プロセスにおいて、テクニカル要素の影響が強くなり、さらに売り注文が多くなる。その結果、価格下落が加速し下落幅が大きくなる。

4 考察

本節では、ファンダメンタル価格急騰時と急落時における各資産の価格推移の違いについて議論する。

まず、3.2 節と 3.3 節より、ファンダメンタル価格が急騰するときと急落するときとは資産価格推移には対称性がないことがわかった。

その理由を以下に述べる。図 6 からわかるように、ファンダメンタル価格の急騰に伴い資産価格が上昇したときは、価格が上昇した資産（資産 1）の違反売り注文が増える。一方、ファンダメンタル価格の急落に伴い資産価格が下落したときは、価格が下落した資産とは異なる他方の資産（資産 2）の違反売り注文が増える。これがファンダメンタル価格急騰時と急落時で資産価格の推移が非対称となった原因である。

この結果から、分散投資規制は、急騰時には価格上昇を止めるという形で影響を与えているのに対し、急

落時には価格を下落させるという形で影響を与えていることがわかる。

次に、分散投資規制が価格形成に与える影響は、急騰時より急落時の方が大きくなる可能性があることが判明した。

理由は次のとおりである。急騰時は急騰した資産が規制違反売りされる一方で、規制なしエージェントは割安となったその資産を購入しようとする。急騰幅が大きいと後者の購入意欲はさらに大きくなる。その結果、急騰時において、規制なしエージェントの割合が小さいときは分散投資規制が価格形成に与える影響は限定的となる。それに対して急落時は、急落した資産とは異なる資産（資産 2）が規制違反売りされるが、資産 2 のファンダメンタル価格は一定であるため、急落直後は規制なしエージェントの注文はまちまちである。しかし規制ありエージェントによる規制違反売り圧力により資産 2 の価格が下落しはじめると、規制なしエージェントの注文プロセスにおいて、テクニカル投資家の成分の影響が大きくなり、売り注文が増加する。その結果、資産 2 の価格下落幅が大きくなる。このことから、分散投資規制が価格形成に与える影響は急騰時に比べ、急落時の方が大きいと考えられる。

5 まとめと今後の課題

本研究では、人工市場を用いて分散投資規制がファンダメンタル価格急騰時の価格形成にどのような影響を与えるか調査し、ファンダメンタル価格急落時のそれとの違いについて議論した。そして、ファンダメンタル価格急騰時はその資産価格の上昇を制限する働きがあることを確認した。また、分散投資規制が急騰時に比べ急落時により大きな影響を与えることを確認した。

今後の課題は以下のとおりである。本研究では、分散投資規制が価格形成に与える影響のみ調査した。しかし、価格形成以外にも運用成績、市場流動性といったさまざまな指標がある。そのため、分散投資規制がファンダメンタル価格急騰時、急落時にそれらの指標にどのような影響を与えるか調査することがあげられる。また、分散投資規制以外の要因からなる資産価格間の相互作用の要因（ファンダメンタルズ価格間の相関、ポートフォリオ投資、パッシブ投資の要因など）をモデルに反映させ、これらの要因と分散投資規制との関連を調査することが挙げられる。

参考文献

[Allen 06] Allen, F., Morris, S., and Shin, H.: Beauty Contests and Iterated Expectations in Asset Markets, *The Review of Financial Studies*, Vol. 19, No. 3, pp. 719–752 (2006)

- [Chen 12] Chen, S.-H., Chang, C.-L., and Du, Y.-R.: Agent-based Economic Models and Econometrics, *Knowledge Engineering Review*, Vol. 27, No. 2, pp. 187–219 (2012)
- [Chiarella 09] Chiarella, C., Iori, G., and Perelló, J.: 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)
- [Cont 01] Cont, R.: Empirical properties of asset returns: stylized facts and statistical issues, *Quantitative Finance*, Vol. 1, pp. 223–236 (2001)
- [Cremers 09] Cremers, M. and Petajisto, A.: How Active Is Your Fund Manager? A New Measure That Predicts Performance, *Review of Financial Studies*, Vol. 22, No. 9, pp. 3329–3365 (2009)
- [Cremers 16] Cremers, M., Ferreira, M. A., Matos, P., and Starks, L.: Indexing and Active Fund Management: International Evidence, *Journal of Financial Economics*, Vol. 120, No. 3, pp. 539–560 (2016)
- [DE LONG 90] DE LONG, J. B., SHLEIFER, A., SUMMERS, L. H., and WALDMANN, R. J.: Positive Feedback Investment Strategies and Destabilizing Rational Speculation, *The Journal of Finance*, Vol. 45, No. 2, pp. 379–395 (1990)
- [広田 09] 広田 真一：バブルはなぜ起こるのか？－ファイナンス理論からの考察－, *証券アナリストジャーナル*, Vol. 47, No. 5, pp. 6–15 (2009)
- [蒲谷 14] 蒲谷 俊介：改正投信法が投信業界に与える影響, *金融 IT フォーカス*, 野村総合研究所, pp. 12–13 (2014)
- [Mizuta 13] Mizuta, T., Izumi, K., Yagi, I., and Yoshimura, S.: Design of Financial Market Regulations against Large Price Fluctuations using by Artificial Market Simulations, *Journal of Mathematical Finance*, Vol. 3, No. 2A, pp. 15–22 (2013)
- [Mizuta 15] Mizuta, T., Izumi, K., Yagi, I., and Yoshimura, S.: Investigation of Price Variation Limits, Short Selling Regulation, and Uptick Rules and Their Optimal Design by Artificial Market Simulations, *Electronics and Communications in Japan*, Vol. 98, No. 7, pp. 13–21 (2015)
- [Nozaki 17] Nozaki, A., Mizuta, T., and YAGI, I.: A Study on the Market Impact of the Rule for Investment Diversification at the Time of a Market Crash Using a Multi-Agent Simulation, *IEICE Transactions on Information and Systems*, Vol. E100.D, No. 12, pp. 2878–2887 (2017)
- [Petajisto 13] Petajisto, A.: Active Share and Mutual Fund Performance, *Financial Analysts Journal*, Vol. 69, No. 4, pp. 73–93 (2013)
- [Sewell 06] Sewell, M.: Characterization of financial time series (2006)
- [Shiller 01] Shiller, R.: Bubbles, Human Judgment, and Expert Opinion, Cowles Foundation Discussion Papers 1303, Cowles Foundation for Research in Economics, Yale University (2001)
- [Shiller 05] Shiller, R.: *Irrational Exuberance*, Broadway Books, Currency/Doubleday (2005)
- [Soros 03] Soros, G.: *The Alchemy of Finance*, John Wiley & Sons, Inc. (2003), (青柳孝直訳：新版 ソロスの錬金術，総合法令出版 (2009))
- [杉田 14] 杉田 浩治：投資信託の 14 年改革と今後の課題, *資本市場，資本市場研究会*, No. 347, pp. 4–11 (2014)
- [The European Parliament and of the Council 09] The European Parliament and of the Council, : DIRECTIVE 2009/65/EC of the European Parliament and of the Council of 13 July 2009 on the coordination of laws, regulations and administrative provisions relating to undertakings for collective investment in transferable securities(UCITS) (2009)
- [Yagi 10] Yagi, I., Mizuta, T., and Izumi, K.: A Study on the Effectiveness of Short-selling Regulation in view of Regulation Period using Artificial Markets, *Evolutionary and Institutional Economics Review*, Vol. 7, No. 1, pp. 113–132 (2010)
- [Yagi 17] Yagi, I., Nozaki, A., and Mizuta, T.: 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)
- [Yamamoto 13] Yamamoto, R. and Hirata, H.: Strategy switching in the Japanese stock market, *Journal of Economic Dynamics and Control*, Vol. 37, No. 10, pp. 2010–2022 (2013)
- [Yeh 13] Yeh, C.-H. and Yang, C.-Y.: Do price limits hurt the market?, *Journal of Economic Interaction and Coordination*, Vol. 8, No. 1, pp. 125–153 (2013)
- [Zhou 17] Zhou, X. and Li, H.: Buying on Margin and Short Selling in an Artificial Double Auction Market, (in press) (2017)

深層学習を用いたマルチファクター運用の実証分析

Deep Learning for Multifactor Models in Japanese Stock Markets

阿部 真也^{1*} 中川 慧¹
Masaya Abe¹ Kei Nakagawa¹

¹ 野村アセットマネジメント株式会社
¹ Nomura Asset Management Co.,Ltd.

Abstract: 株価を予測するために、様々なファクターが特徴量として多数提案されてきた。一方で、近年これら大量のファクターを同時に扱うために、機械学習、とりわけ深層学習を用いた株価予測手法が提案されてきた。しかしながら、日々の運用を意識した具体的な実践事例はほとんどない。そこで本稿では、日本株式市場において機械学習を用いたマルチファクターモデルに基づく実運用を意識した実証分析を行う。そして、深層学習の有効性を確認するとともに、分析を通じて得た知見について考察する。

1 はじめに

株価を予測するためのアプローチとして、(1) 株価を時系列データとみなして予測する方法、(2) あるクロスセクション(断面)での銘柄間の相対的な順位に基づいて予測する方法の2つがある。一般的な時系列データとは異なり、株価を時系列データとしての予測、すなわち過去の株価を特徴量として利用し、将来の株価を予測するという前者のアプローチは短期的には可能でも、長期的には難しいことが知られている。一方で、後者の複数の株価をクロスセクションデータとして見た中で、どういった銘柄群が相対的にリターンが高くなり、どういった銘柄群が低くなるかは、中長期的な期間である程度明らかにされている。こういったクロスセクションで株価を説明する要因を「ファクター」という。ファイナンスの学術的には、[4]によるFama-Frenchの3ファクターモデルが一般的である。これはベータ、サイズ、バリュウの3つのファクターがクロスセクションで月間の株価変動を説明することを明らかにした。以降、[5]によれば、2012年までの間に316ものファクターが発見された。しかも、これらファクターの大部分は過去10年の間に見つかった。そのため近年、運用者が検討すべきファクターは急速に増大しているものの、「次元の呪い」の問題から316ものファクターを同時に検証することはできない。一方で、ファイナンスにおいては統計的な扱いや理論的な解析が容易であること、結果の頑健性から線形回帰モデルを用いる。実

務的には、これらのうち幾つかのファクターと将来リターンとの回帰(マルチファクターモデル)から、ある銘柄についての総合的な魅力度を計算し、当該魅力度に基づいてポートフォリオ構築を行う。しかしながら、資産価格変動は非線形性を持つことが古くから知られているため、単純な線形モデルでは予測精度に限界がある。以上の背景から、機械学習の手法を用いてこれらの問題に取り組んでいる研究が学術的には盛んである[2, 3]。

しかしながら、クロスセクションでのマルチファクターモデルの観点から、機械学習を適用する試みは[7, 1, 6]といった少数の例を除くとあまりなく、特に様々なファクターを用い、実運用を意識した分析例は存在しない。そこで、以上の問題設定から本稿では、日本株式市場において機械学習、特に、画像認識、音声認識、自然言語処理など様々なタスクにおいて、優れた非線形関数近似能力を示している深層学習を用いたマルチファクターモデルに基づく実証分析を行う。

2 深層学習を用いたマルチファクター運用

実務的にはデータ、特徴抽出、予測モデル構築、ポートフォリオ構築というプロセスで運用を行う(図1)。まず、データとしてPERやROEなどの株価を説明するであろう指標(ディスクリプター)を幾つか用意する。[4]などのファイナンスの学術研究とは違い、それらのディスクリプターを標準化したものを複数組み合わせる。例えば、株価の割安感を表すバリュウファクターを、PBR、PER、配当利回りを1:1:1

*連絡先: 野村アセットマネジメント株式会社
〒103-0027 東京都中央区日本橋1丁目12-1
E-mail: m-abe@nomura-am.co.jp

本稿の内容は筆者らが所属する組織を代表するものではなく、本稿の全ての誤りは、筆者らの責に属するものである。

で組み合わせて作る。そして複数のファクターから回帰モデルで株式リターンを予測する。最後に予測された株式リターンとリスクを用いてポートフォリオを構築する。

従来はディスクリプターからファクターの作成、そしてどのファクターをいくつ使うのかを人が選択していたため、モデルの見直し・チューニングには非常に多くの時間がかかった。またそれらの多くは運用者であるファンドマネージャーの経験によって決定されていた。しかしながら、ディスクリプターから株式リターンの予測を表現力に優れた深層学習を用いて置き換えることで、長年の経験をパラメータチューニングに置き換えることができる。

具体的には、ディスクリプターをインプットとして与え、アウトプットとして将来リターンを与える。すると隠れ層にはこれらディスクリプターが非線形に合成された「ファクター」が表現される。

3 実証分析

3.1 データセット

ここでは日本株式市場を対象に分析を行う。分析のユニバースとして、機関投資家の投資対象として使用されることの多い TOPIX500 指数構成銘柄とした。TOPIX500 指数は東証 1 部上場株式の時価総額の 90% 程度をカバーする株式指数である。特徴量として用いるディスクリプターは表 1 の通りである。これらのディスクリプターの計算のため、予想利益と目標株価 (No.13-18) は I/B/E/S から、その他のデータは Factset、WorldScope と Reuters Fundamentals から取得した。ただし、No.19 以降は毎月末に値が変わる月次データとして扱った。これらのディスクリプターはすべて実務でよく使用されるものである。

3.2 分析方法と考察

実際の運用を見据え、毎営業日ポートフォリオを入れ替える実証分析を行う (図 2)。特徴量として、表 1 を用い、教師データは翌営業日の寄りから 5 営業日先までのリターンとする。また各データは時点毎に 0 から 1 のパーセンタイル化の前処理を行っている。訓練データセット数は直近過去 1,000 個を用いる。これを用いてモデルの学習を行い、各銘柄の予測スコアを算出する。なお、モデルの学習間隔は 5 営業日としている。検証期間は 2012 年 12 月 28 日～2017 年 12 月 29 日であり、直近の特徴量をモデルに与え、毎日引け後に予測スコアを出す。そしてリバランスのタイミングによる影響を減らすために、5 営業日サイクルで 5 本の

ポートフォリオを構築する。これらをポートフォリオ 20% ずつ保有する。各ポートフォリオは予測スコア上位 5 分位の買いの等ウェイト (5 分位ポートフォリオ)、または予測スコア上位 5 分位の買い、予測スコア下位 1 分位の売りの等ウェイト (5 分位-1 分位ポートフォリオ) として構築される。流動性の観点からポジション構築タイミングは予測スコア計算の翌営業日の寄りとする¹。したがって、日々のパフォーマンスの計測も寄り基準としている。5 分位-1 分位ポートフォリオは、5 分位ポートフォリオから 1 分位ポートフォリオのリターンを引いて、5 分位ポートフォリオは TOPIX500 の等ウェイトリターンを引いてポートフォリオのリターンを計測する。

具体的なモデルとして下記を用いる。

1. 深層学習 (DNN): パッケージ TensorFlow を用いて実装を行った。7 層の全結合型の構造で、活性化関数は全て ReLU 関数を用いた。隠れ層およびドロップアウトの構造とエポック数は表 2 の通り。最適化アルゴリズムに学習率 0.001 の Adam を用い、ミニバッチサイズは 500 とした。バイアスの初期値を 0、そしてウェイトの初期値を TensorFlow の関数 "tf.truncated_normal" の平均 0、標準偏差を $\sqrt{2/M}$ として与えた。ただし、M は前層のユニットのサイズである。
2. ランダムフォレスト (RF): パッケージ scikit-learn のクラス "sklearn.ensemble.RandomForestRegressor" を用いて実装を行った。パラメータについては特徴量の数 (max_features) を 11 (=33/3)、木の数 (n_estimators) を 1,000、深さ (max_depth) を {3, 5, 7} とした。深さの浅い順にそれぞれ RF_1 から RF_3 とする。
3. リッジ回帰 (RR): パッケージ scikit-learn のクラス "sklearn.linear_model.Ridge" を用いて実装を行った。正則化パラメータ (alpha) は {0.1, 1, 10} とした。正則化パラメータの小さい順にそれぞれ RR_1 から RR_3 とする。

3.3 分析結果

5 分位-1 分位ポートフォリオ、5 分位ポートフォリオの結果のサマリーがそれぞれ表 3、4 である。年率リターン、リスク、リターン/リスク比 (R/R)、最大ド

¹引けまでのデータを用いて、予測スコアを計算し、引けでリバランスを行う研究もあるが、これは実際には不可能である。また日々の出来高は寄りが最も多い傾向があるため、寄りでのリバランスを想定している。

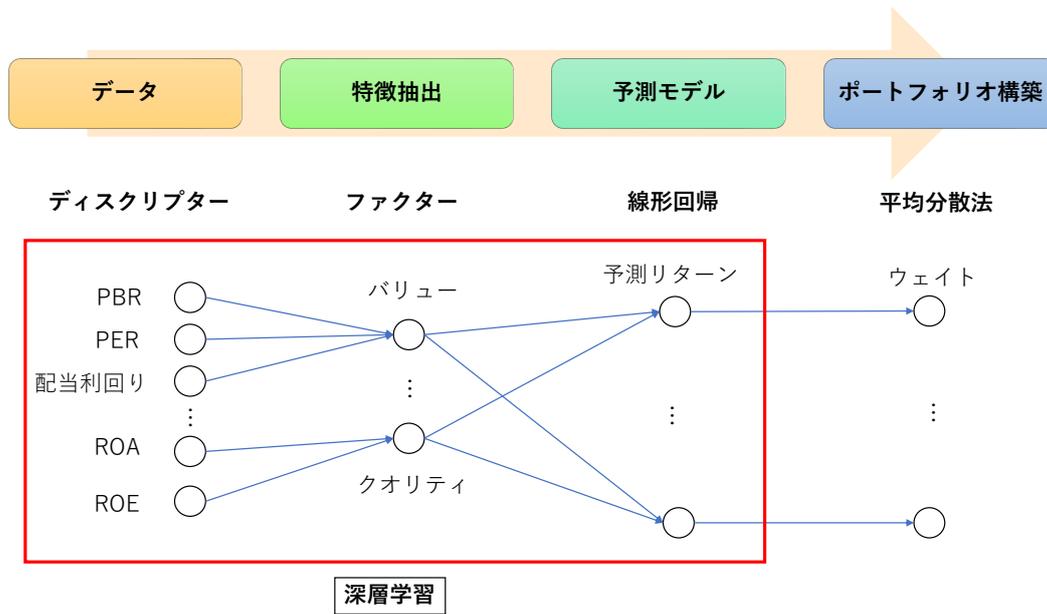


図 1: 深層学習を用いた株価予測のアプローチ

表 1: 使用したディスクリプターの定義

No	ディスクリプター	内容
1	当日リターン	-
2	対 2 日前リターン	-
3	対 3 日前リターン	-
4	対 5 日前リターン	-
5	対 10 日前リターン	-
6	対 20 日前リターン	-
7	対 40 日前リターン	-
8	対 60 日前リターン	-
9	過去 60 日の平均売買金額	-
10	過去 5 日/過去 60 日の売買金額	-
11	過去 10 日/過去 60 日の売買金額	-
12	過去 20 日/過去 60 日の売買金額	-
13	営業利益予想の変化 (対 5 日前)	-
14	営業利益予想の変化 (対 10 日前)	-
15	営業利益予想の変化 (対 20 日前)	-
16	目標株価の変化 (対 5 日前)	-
17	目標株価の変化 (対 10 日前)	-
18	目標株価の変化 (対 20 日前)	-
19	B/P	総資産/時価総額
20	E/P	当期純利益/時価総額
21	D/P	配当/時価総額
22	S/P	売上高/時価総額
23	CF/P	営業キャッシュフロー/時価総額
24	ROE	純利益/純資産
25	ROA	営業利益/総資産
26	ROIC	税引後営業利益/(有利子負債+株主資本)
27	アクルーアルズ	-(流動資産の変化+現金の変化-流動負債の変化-減価償却費)/総資産
28	総資産回転率	売上高/総資産
29	流動比率	流動資産/流動負債
30	自己資本比率	純資産/総資産
31	総資産成長率	総資産の前期からの成長率
32	CAPEX 成長率	資本的支出の前期からの成長率
33	Investment to Asset	有形固定資産の取得による支出の前期からの成長率/総資産



図 2: ポートフォリオの構築例

表 2: 深層学習の構造

モデル	隠れ層 (ドロップアウト)	エポック数
DNN_1	500-200-100-50-10 (50%-40%-30%-20%-10%)	20
DNN_2	500-200-100-50-10 (50%-40%-30%-20%-10%)	30
DNN_3	200-200-100-100-50 (50%-50%-30%-30%-10%)	20
DNN_4	200-200-100-100-50 (50%-50%-30%-30%-10%)	30
DNN_5	300-300-150-150-50 (50%-50%-30%-30%-10%)	20
DNN_6	300-300-150-150-50 (50%-50%-30%-30%-10%)	30

ローダウン (最大 DD)² を評価指標とする。なお、表中の太字は DNN, RF, RR それぞれの手法内で最も良いものを表している。

表 3, 4 とともに、DNN はモデルのパラメータの違いによるリターンとリスクの差が大きい。これは DNN の構造設定における自由度の高さを始め、調整すべき (ハイパー) パラメータの数が多いことが要因として考えられる。学習度合いとなるエポック数で比較すると、20 の方が 30 のケースよりも全体的にパフォーマンスが良く、今回検証した DNN は、30 まで学習させると過学習してしまう結果となった。RF と RR については、DNN に比べて調整するパラメータの自由度が低いため、パラメータによる差が小さい。特に RR についてはほぼ同等である。RF はほぼすべてのモデルで DNN に劣後しているものの、RR はパラメータによっては DNN を上回っている。特に買いのみの表 4 で DNN を上回っているケースが多い。パラメータ調整や学習の容易さを考えると、買いのみの 5 分位ポートフォリオでは DNN より RR が好ましいといえる。ただし、年

²リターンの最大収益時からの下落率をドロウダウンという。そのドロウダウンが最大のケースを最大ドロウダウンといい、リスク指標として用いられる。

表 3: 5 分位-1 分位ポートフォリオの結果

モデル	年率リターン	年率リスク	年率 R/R	最大 DD
DNN_1	8.74%	6.04%	1.45	-7.00%
DNN_2	6.83%	5.56%	1.23	-6.01%
DNN_3	11.37%	7.23%	1.57	-10.34%
DNN_4	10.00%	6.63%	1.51	-10.40%
DNN_5	11.42%	6.46%	1.77	-8.42%
DNN_6	8.97%	6.13%	1.46	-8.26%
RF_1	7.28%	9.38%	0.78	-20.86%
RF_2	6.69%	9.28%	0.72	-19.56%
RF_3	6.86%	9.23%	0.74	-17.88%
RR_1	10.98%	8.50%	1.29	-13.37%
RR_2	10.98%	8.50%	1.29	-13.36%
RR_3	10.96%	8.50%	1.29	-13.36%

率のリスクと最大ドロウダウンに着目すると、DNN は小さい傾向であり、リスクを回避した運用を行う場合には DNN の方に優位性がある。一方で、買いと売りの表 3 では、RR よりも DNN が比較的良い。これは一般に買い側と売り側で魅力的な銘柄が異なるため、非線形性を考慮できる DNN が売り側でも収益を獲得できていると考えられる。なお、回転率については、いずれもモデルも一度のリバランスで 50% 前後となっており、DNN はその他のモデルよりも 5% 程度高い。しかしながら、取引コストを考慮しても、今回の考察の結論は変わらない。

4 おわりに

本稿では、深層学習を用いた株価予測モデルを実際の運用と同様の条件で検証を行った。TOPIX500 を対象とした実証分析の結果、以下の知見が得られた。

- 深層学習による株価予測モデルはランダムフォレストやリッジ回帰に比べパラメータによるパフォーマンスの差が大きい。
- 深層学習モデルは買い、売りの両方で収益獲得の機会がある。

表 4: 5 分位ポートフォリオの結果

モデル	年率リターン	年率リスク	年率 R/R	最大 DD
DNN_1	4.24%	3.06%	1.39	-3.15%
DNN_2	3.36%	3.07%	1.09	-4.01%
DNN_3	5.15%	3.53%	1.46	-3.84%
DNN_4	4.40%	3.21%	1.37	-6.08%
DNN_5	5.11%	3.01%	1.70	-3.46%
DNN_6	4.00%	2.86%	1.40	-4.14%
RF_1	3.02%	4.47%	0.68	-8.23%
RF_2	3.02%	4.49%	0.67	-8.75%
RF_3	2.68%	4.46%	0.60	-9.72%
RR_1	5.95%	3.82%	1.56	-4.03%
RR_2	5.96%	3.82%	1.56	-4.03%
RR_3	5.95%	3.82%	1.56	-4.04%

- 低リスクという観点で、深層学習モデルは優れている。

参考文献

- [1] Masaya Abe and Hideki Nakayama. Deep learning for forecasting stock returns in the cross-section. In *Pacific-Asia Conference on Knowledge Discovery and Data Mining*, pp. 273–284. Springer, 2018.
- [2] Arash Bahrammirzaee. A comparative survey of artificial intelligence applications in finance: artificial neural networks, expert system and hybrid intelligent systems. *Neural Computing and Applications*, Vol. 19, No. 8, pp. 1165–1195, 2010.
- [3] Rodolfo C Cavalcante, Rodrigo C Brasileiro, Victor LF Souza, Jarley P Nobrega, and Adriano LI Oliveira. Computational intelligence and financial markets: A survey and future directions. *Expert Systems with Applications*, Vol. 55, pp. 194–211, 2016.
- [4] Eugene F Fama and Kenneth R French. The cross-section of expected stock returns. *the Journal of Finance*, Vol. 47, No. 2, pp. 427–465, 1992.
- [5] Campbell R Harvey, Yan Liu, and Heqing Zhu. ... and the cross-section of expected returns. *The Review of Financial Studies*, Vol. 29, No. 1, pp. 5–68, 2016.
- [6] Kei Nakagawa, Takumi Uchida, and Tomohisa Aoshima. Deep factor model. In *MIDAS 2018 : MIDAS @ECML-PKDD 2018 - 3rd Workshop on Mining Data for financial applicationS*, 2018.

- [7] 杉友盛佑, 南正太郎. ファンダメンタルファクターモデル (リターンモデル) における機械学習手法の応用可能性検証. 人工知能学 金融情報学研究会 (SIG-FIN), 2017.

外国為替市場におけるトレーディング戦略分類

Classification of trading strategies in a forex market

末重拓己¹ 金澤輝代士^{1,2} 高安秀樹^{2,3} 高安美佐子^{1,2}

Takumi Sueshige¹, Kiyoshi Kanazawa², Hideki Takayasu^{2,3}, and Misako Takayasu^{1,2}

¹ 東京工業大学 情報理工学院

¹ Department of Mathematical and Computing Science, School of Computing, Tokyo Institute of Technology

² 東京工業大学 科学技術創成研究院

² Institute of Innovative Research, Tokyo Institute of Technology

³ Sony Computer Science Laboratories

Abstract: Recent popularity in algorithmic trading has spurred on researchers to investigate the variety and the evolution of the trading strategies. In this talk, we present our recent study (under review in PLOS ONE), in which the strategy distribution of limit orders is analyzed by using the high frequency data set including anonymized trader IDs. We first identify timescales for each trader to measure market-price trends by the multi-regression analysis. Clustering the timescales into several clusters, we then show the frequencies of the submissions and transactions for each cluster. Furthermore, we provide the microstructure insight to their frequencies in terms of the average shape of limit orders. Finally, we quantify the activity level of each cluster, and show that some clusters are unique to the local time in Tokyo or New York.

1 導入：トレーダごとの戦略解析

近年の電子技術の発展により、特に金融市場においては様々な種類のデータの入手が容易になってきた。その中でも特に注目を浴びているのが、取引履歴にトレーダ ID が付帯したデータである。トレーダ ID 付きのデータを用いることで、個々のトレーダの取引履歴を追跡することができ、取引のパターンなどから戦略分類をすることができる[1-5]。事実、[5]では、1 日ごとにトレーダ名義で取引高を記録した Euroclear Finland の 5 年分のデータから、Statistically Validated Network というネットワーク構築手法を用いて取引をネットワークとして構造化したうえで、どのコミュニティにおいて取引の連動性が高いかを分析している。

しかし、取引と取引間の戦略、つまり指値注文や成行注文の戦略についてはほとんど研究がおこなわれていない。外国為替市場においては、1 回の取引の裏側には、数十の指値注文が戦略的に出されては取り消されてたりしている。そのため、指値注文の戦略にはトレーダの取引戦略を理解するうえで重要な情報が含まれていると考えられる。さらに、トレーダごとの戦略を分類した先行研究の多くは、1 日ごとに合算したデータを使っており、高頻度データを

用いた研究はほとんどない。そこで本研究では、Electronic Broking System (EBS)社から提供されたトレーダ ID 付き、かつ全注文が millisecond 単位で記録されている外国為替市場の高頻度データを用いて、個々のトレーダごとに指値注文の戦略を特定し、その類似性からクラスターを構築する。トレーダの戦略分類は、トレンドと呼ばれる、過去一定期間内の取引価格推移の大きさをもとに行った。本研究の内容をより詳細にまとめた論文が現在 PLOS ONE にて査読されている。

2 研究結果

本研究では、EBS 社が提供するドル円インターバンク市場のデータ (2016 年 6 月 5 日~10 日) を用いて解析を行った。このデータでは指値注文の発注と取消、成行注文の発注とその成否が millisecond でトレーダ ID 付きで記録されている。指値注文で指定できる価格の最小単位は 0.001 円であり、この最小単位を **tpip (tenth pip)** と呼ぶ。また、時間の定め方として、取引が行われたごとにインクリメントされていく時間を **tick 時間** と呼び、時間の単位として用いる。以上のデータと用語定義のもとトレーダの戦略分類を行った。

2.1 トレンドの時間スケール特定手法

個々のトレーダにとってのトレンドを測定するにあたり、トレーダがどの程度過去までの取引価格を用いているのかを特定する必要がある。そこで先行研究[2]の結果を用いる。[6,7]では、個々のトレーダの指値注文に対して、

$$\Delta z_i(t) = c_i \tanh\left(\frac{\Delta p(t-1)}{\Delta p_i^*}\right) \dots (1),$$

という関係が示された。ここで $\Delta z_i(t) = z_i(t+1) - z_i(t)$, $z_i(t) = (z_i^-(t) + z_i^+(t))/2$ であり、 $z_i^-(t)$, $z_i^+(t)$ はそれぞれ時刻 t におけるトレーダ i の Bid と Ask の指値注文を意味する。また、 $\Delta p(t) = p(t+1) - p(t)$ であり、 $p(t)$ は時刻 t における取引価格である。 c_i , Δp_i^* はそれぞれトレーダ i 固有の定数であり、典型的には 6.0tpip と 7.5tpip である。

本研究では、先行研究で限定していた過去 1tick の取引価格変化との相関構造を、過去数 tick までさかのぼり、そのうち有意とみなせる期間をトレンドの時間スケールと定義する。具体的には、

$$\Delta P_i^{\text{Trend}}(t) \equiv \sum_{k=1}^{K_i} w(k) \Delta p^{(j_i)}(t-k),$$

$$\Delta z_i(t) = c_i \tanh(\Delta P_i^{\text{Trend}}(t) + \alpha_i),$$

と拡張する。ここで、

$$\Delta p^{(j_i)}(t-k) \equiv p(t-j_i(k-1)) - p(t-j_i k),$$

であり、 j_i は取引価格差を疎視化する範囲を意味する。この式を用いた結果、取引価格差の重み $w(k)$ は、

$$w(k) \approx d_i \exp\left(-\frac{k}{\tau_i}\right)$$

と近似できることが分かった。これは、トレーダが指数関数を用いてトレンドを定義していることを意味し、指数移動平均法が実務としてよく使われている事実[8]と整合する。指数関数で近似される場合、その典型的な時間スケールは τ_i で記述されるため、祖視化の時間スケール j_i との積、つまり $\tau_i j_i$ をトレーダのトレンド測定的时间スケールとして定義した。

2.3 トレンドの時間スケールのクラスタリング

2.2 までで得られた個々のトレーダのトレンド測定的时间スケールを、機械学習の分野で標準的な手法の一つである k -means を用いて 3 種類のクラスタに分類した。それぞれ平均的に 5tick (30 Sec 程度)、15tick (3 min)、30tick (6 min) 程度過去の情報を参照する Short-time cluster, Intermediate-time cluster, Long-time cluster である。2.2 のプロセスで指数関数に従わないトレーダのクラスタ non-EMA cluster を併せて

全 4 クラスタに分類した。

2.4 クラスタごとの取引頻度

2.3 までのクラスタ分類に基づき、それぞれのクラスタの取引回数を調べた。その結果、Intermediate-time cluster が 4 クラスタの中で最も取引回数が少ないことがわかった。その理由として、指値注文分布の平均形状があげられる。分類したクラスタごとに指値注文分布を計算したところ、intermediate-time cluster の平均形状のピークは best price から最も遠いところに位置することが分かった。つまり、intermediate-time cluster に所属するトレーダは、平均的に best price から遠い価格に指値注文を出しているため取引回数が少ないといえる。さらに、各クラスタがどの時間帯に特徴的な戦略であるのかを、各クラスタの指値注文総量が全体の指値注文分布に占める割合から調べた。その結果、short-time cluster は日本時間において特徴的な戦略であるのに対し、intermediate-time cluster はニューヨーク時間に特徴的な戦略であることがわかった。ここから、日本時間に活動するトレーダは現時点での価格で取引することに積極的であるのに対して、ニューヨーク時間に活動するトレーダは、現時点での価格で取引することに消極的である傾向が読み取れる。

3 まとめと今後の展望

本研究では、トレンドと呼ばれる過去の取引価格推移に着目し、外国為替市場における指値注文戦略の特定、およびその分類を行った。そして、それぞれのクラスタの取引回数を調べ、その大小関係を指値注文分布の形状から意味付けを行った。最後に、分類した戦略がどの時間帯に特有であるのかを調べ、日本時間とニューヨーク時間に特有な戦略の特定を行った。本研究により指値注文戦略の全体像を把握することができたため、ここで明らかになった戦略をもとに人工市場を構築し、i) 利益を判断基準として戦略間の相性分析を行う、ii) 特定の戦略を人工市場から除いた時、価格差の統計則へのインパクトを計測することなどが今後の展望として考えられる。

謝辞

本研究を進めるにあたり、C. Osler 氏, J. Ozaki 氏, K. Tamura 氏, M. Yamada 氏および T. Ito 氏との議論が参考になりました。ここで謝辞させていただきます。また、本研究は学術振興会特別研究員研究奨励費 (No. 17J10781)、科学研究費補助金若手研究 B (No. 16K16016)、戦略的国際共同研究プログラム (SICORP)

から援助されていること明記させていただきます。

参考文献

- [1] Odean, Terrance.: Are investors reluctant to realize their losses?, *The Journal of finance*, Vol. 53, No. 5, pp. 1775—1798 (1998).
- [2] Grinblatt, M., & Keloharju, M.: The investment behavior and performance of various investor types: a study of Finland's unique data set., *Journal of financial economics*, Vol. 55, No. 1, pp 43—67 (2000).
- [3] de Lachapelle, D. M., & Challet, D.: Turnover, account value and diversification of real traders: evidence of collective portfolio optimizing behavior., *New Journal of Physics*, Vol. 12, No. 7, pp. 075039, (2010).
- [4] Musciotto, F., Marotta, L., Piilo, J., & Mantegna, R. N.: Long-term ecology of investors in a financial market., *Palgrave Communications*, Vol. 4, No. 1, pp. 92 (2018).
- [5] Tumminello, M., Lillo, F., Piilo, J., & Mantegna, R. N.: Identification of clusters of investors from their real trading activity in a financial market, *New Journal of Physics*, Vol. 14, No. 1, 013041, (2012).
- [6] Kanazawa, K., Sueshige, T., Takayasu, H., & Takayasu, M.: Derivation of the Boltzmann equation for financial Brownian motion: Direct observation of the collective motion of high-frequency traders, *Physical review letters*, Vol. 120, No. 13, 138301, (2018)
- [7] Kanazawa, K., Sueshige, T., Takayasu, H., & Takayasu, M.: Kinetic Theory for Finance Brownian Motion from Microscopic Dynamics. arXiv preprint arXiv:1802.05993, (2018)
- [8] Grebenkov DS, Serror J.: Following a trend with an exponential moving average: Analytical results for a Gaussian model., *Physica A.*, Vol. 394, pp. 288—303 (2014)

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画像認識やゲーム AI の分野を中心に活発に行われている。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[1]。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、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が確認できた[2]。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、これらを全て考慮するには、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裁定取引である。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されるため、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。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[2]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裁定取引を考える。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。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単位ずつの売りもしくはポジションの解消に制限した。よって、投資比率と複利リターンを考慮する必要がない。

(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先物の裁定取引単位（1単位）はTOPIXの10,000倍である。NT買い（売り）ポジションとは、1単位以上NT買い（売り）をしている状態を指し、それを解消することは買った分を売り、空売りした分を買い戻すことを指す。

(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、学習していない未知の状態に陥ってしまう可能性があるからである。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た。

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6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。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（TOPIX先物： T ）、 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の最大 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の最低 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 6 つを状態変数として学習を行う．

(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 の時のグロス利益率 (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．その上でポジションの状態に応じた適切な報酬を与えられるように，以下の 3 つの場合に分けて報酬を与える．

- ポジションを取得した時

ポジションを取得した時には，順張りの取引を意識して報酬 r を以下のように定める．

$$r = \begin{cases} O_t \times \omega_1 & \text{if } pos = long \text{ and } O_t > 0 \\ |O_t| \times \omega_1 & \text{if } pos = short \text{ and } O_t < 0 \\ 0 & \text{otherwise} \end{cases} \quad (3)$$

ここで， O_t は相対 NT 倍率， ω_1 はその重み， pos は現在のポジションで $long$ は NT 買いポジション， $short$ は NT 売りポジションである．これにより，NT 買いポジションをとった時に NT 倍率が過去 k 期間の平均と比べて高ければ，その分だけ報酬を与え，NT 売りポジションをとった時に NT 倍率が過去 k 期間の平均と比べて低ければ，その分だけ報酬を与えることを表す．

- ポジション保持状態の時

ポジションを解消せず，保持し続けている時には， t 日目の含み損益 $prof_t$ を用いて報酬 r を以下のように定める．

$$r = (prof_t - prof_{t-1}) \times \omega_2 \quad (4)$$

ここで， ω_2 は含み損益の重みである．これにより，

含み損益を増やすような行動に対して報酬を与えることができる．

- ポジションを解消した時

ポジションを解消した時には，その時に得られる損益である t 日目の実現損益 $Rprof_t$ を用いて報酬 r を以下のように定める．

$$r = Rprof_t \times \omega_3$$

$$Rprof_t = \frac{P_t^N \times S_t^N + P_t^T \times S_t^T}{A_0} \quad (5)$$

ここで， ω_3 は実現損益の重みである．これにより，実現損益が高くなるタイミングでの利益確定ができるようになると思われる．

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マイナス 1 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い， M 回取引を行い，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．この際の行動選択には，パラメータ ϵ 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 ϵ -greedy 法を用いる．

③ ニューラル・ネットワークの更新

集めた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 と a 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．

$$q_t \leftarrow r + \gamma \max_{a'} Q(X', a') \quad (6)$$

ここで， r は 2.1 で決めた報酬， γ 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。それぞれの NT 倍率の推移を図 2 に示す。

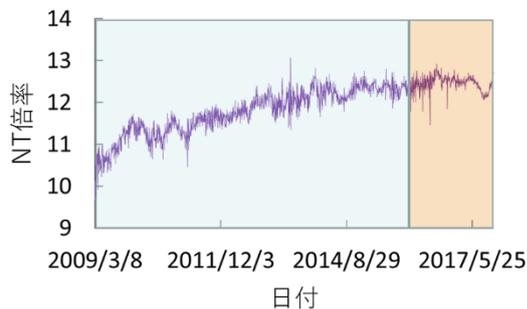


図 2 : NT 倍率の推移.

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 36, 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 ϵ -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 ϵ は 0 エピソード時には 1.00 とし、50,000 エピソードかけて 0.05 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 $k = 5$ 、報酬の重みはそれぞれ $\omega_1 = 2.0, \omega_2 = 3.0, \omega_3 = 5.0$ とした。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。

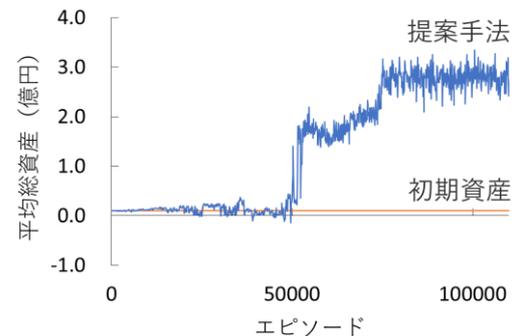


図 3 : 学習期間の最終総資産の推移.

図 3 の横軸はエピソード、縦軸は総資産である。青い折れ線グラフは、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、50,000 エピソードまでは初期資産の周りを振動するだけであるが、それ以降に大きく総資産を伸ばし、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。

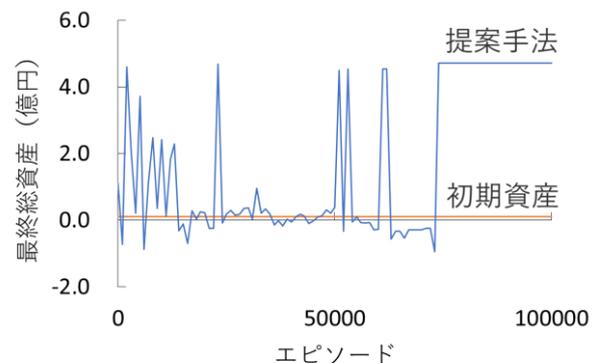


図 4 : テスト期間の最終総資産の推移.

図 4 の横軸はエピソード、縦軸は総資産である。青い折れ線グラフは、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、橙色の直線は初期資産である。テスト期間は 1000 エピソード毎に行うため、序盤はかなり激しく振動しているが、最終的には初期資産よりもかなり高い値で収束していることが分かる。

最後に、状態変数の「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)」がある場合とない場合の学習期間での比較を図 5 に示す。

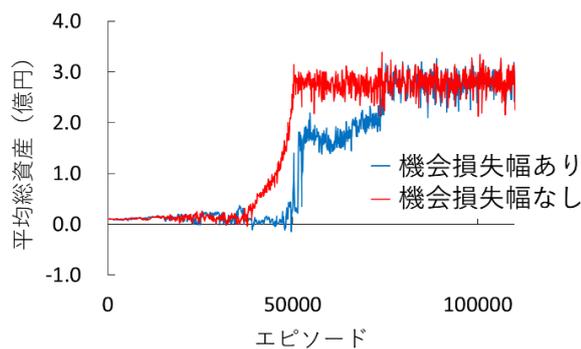


図 5：機会損失幅の有無の比較

図 5 の横軸はエピソード，縦軸は総資産である。こちらは図 3 と同様に学習期間の平均最終総資産の推移であり，青の折れ線グラフが機会損失幅あり，赤の折れ線グラフが機会損失幅なしである。これを見ると，序盤と終盤は同じような動きをしていることが分かる。しかし，中盤において機会損失幅がある方が，総資産の上昇が遅い。これは機会損失幅という新しい情報を受けて，新しい方策を創出しようとしているが，うまくいかずに同じ値で収束してしまっている，つまりは新しい情報を活かしてきれていないと考えられる。

また，どちらも最終的に同じ値の周辺で収束しているが，この時にどんな行動をとっているのかを調べたところ，基本的に「1 単位 NT 買い（日経 225 先物買い，TOPIX 先物売り）」をし続けていることが分かった。それ以外の行動をとることもあるが，それは ϵ -greedy 選択によるランダム行動のときのみである。これは，学習期間の NT 倍率が長期的にみると上昇トレンドであるため，NT 買いをし続けることである程度稼ぐことができしまい，「NT 買いをし続ける」という局所解に陥ってしまっていると考えられる。

5. 今後の課題

実験結果より，上昇トレンドに特化した「NT 買いをし続ける」方策を学習していることが分かった。しかし，NT 倍率が長期的に見て上昇トレンドであるとは言え，そこだけで稼ぐのではなく，短期的な下降トレンドでも利益を出せる方がより大きな利益を出せるはずである。今回の結果から，機会損失幅がある場合でもその情報を上手く活かしてきれていないことが分かった。そのため，機会損失幅を状態変数に加えるだけでなく，報酬にもある程度の影響を与えるように変更することを検討している。また，学習期間の NT 倍率が長期的に見て上昇トレンドであることも原因の 1 つであると考えられるため，そこ

も改善が必要である。具体的には学習期間を短くし，上昇トレンドの比率を相対的に小さくすることなどを検討中である。

さらに，現在は Deep Q-Network という学習方法を用いているが，最新の手法として A3C [3] というものが開発されている。A3C (Asynchronous Advantage Actor-Critic) は，Deep Q-Network を発展させたモデルである。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，非同期的に複数のエージェントから集めたデータを用いてニューラル・ネットワークの重みの変更を行うため，データをランダムサンプリングする必要がない。それによって LSTM [4] 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] 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)
- [2] 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)
- [3] 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)
- [4] Sepp Hochreiter, Jürgen Schmidhuber : Long Short-Term Memory, Neural computation, 9(8), pp. 1735–1780 (1997)

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¹ 穴田 一¹

Ohki Kato¹ Hajime Anada¹

¹ 東京都市大学大学院 総合理工学研究科

¹ 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多く行われている。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。

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、より利益を生み出すテクニカル指標を用いた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[1][2]。それぞれの数字がテクニカル指標や売買行動を表し、各ノードから一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。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。使用するノードは松村らの研究にならう。表1に終端ノードと非終端ノードの例を示す[1][2]。

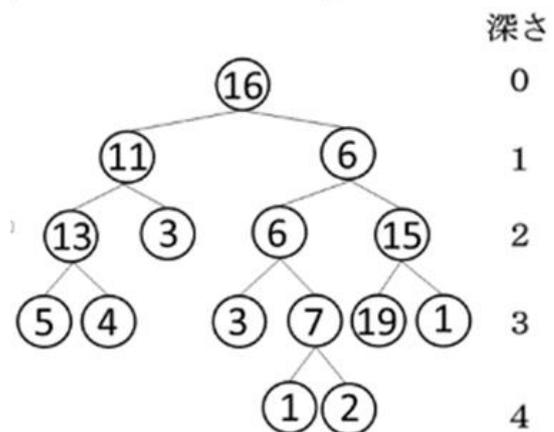


図1 戦略木の例

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、左右どちらかのノードを実

行するのかが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。

表1 ノードの例

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	保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
非終端ノード	6	前日の終値が前々日の終値を上回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
	⋮	⋮
	34	前日の総資産が前々日の総資産を上回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

2.3. 遺伝子操作

戦略木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、取引させた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が決まっているため、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6番のノードがある。深さ1にある6番で左のノードを実行する場合、深さ2の6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7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いうからである。

2.3.4. 交叉

現世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

現世代の個体N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、 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 $p(\%)$ に基づき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現世代のN個体と、交叉と突然変異によってできたN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) 初期個体のノード削除
- IV) 交叉
- V) 交叉によって出来た個体の評価
- VI) 交叉によって出来た個体の使われないノード削除
- VII) 突然変異
- VIII) 突然変異した個体の評価
- IX) 突然変異した個体の使われないノード削除
- X) 次世代に残す個体の選択

IV)~X)を、決められた世代数まで繰り返す。

3. 結果

本研究では、取引銘柄は東京証券取引所 1 部に上場している銘柄とした。使用したのは、出来高が多く長い期間データを取ることが出来る表 2 の 10 銘柄である。

表 2 取引銘柄

業種	銘柄
製造業	キャノン
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、学習を行う学習期間とテストを行うテスト期間を表 3 のように設け、シミュレーションを行った。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

とし取引を行い、2 年刻みであれば、1 銘柄につき 6 年間の学習期間を 2005 年 1 月~2006 年 12 月、2007 年 1 月~2008 年 12 月、2009 年 1 月~2010 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。テスト期間の特徴として、ケース 1 は横ばい、ケース 2 はなだらかな上昇トレンド、ケース 3 は激しい上下変動をとまなう上昇トレンドとなっている。

表 3 取引期間

学習期間	テスト期間	
2005 年 1 月~2010 年 12 月	ケース 1	2011 年 1 月~2012 年 12 月
	ケース 2	2013 年 1 月~2014 年 12 月
	ケース 3	2015 年 1 月~2016 年 12 月

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。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。

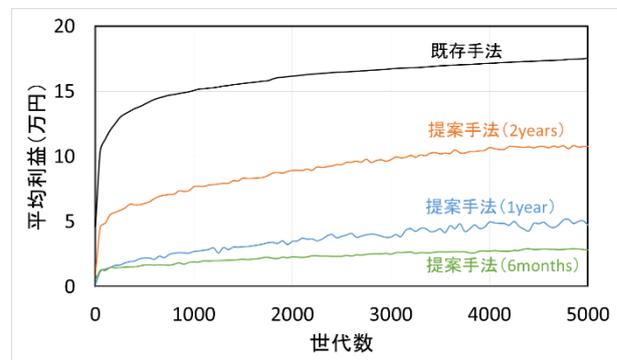


図 2 最良個体の平均利益の世代推移 (学習期間)

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てい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 にその世代で適応度が最も高い個体のケース 1 のテスト期間での利益を示す。この図は、50 試行を平均したものであり、縦軸は利益(万円)、横軸は世

代数を表し、黒線は既存手法の利益、オレンジ線は2年刻みによる提案手法の利益、青線は1年刻みによる提案手法の利益、緑線は6ヶ月刻みによる提案手法の利益を表す。

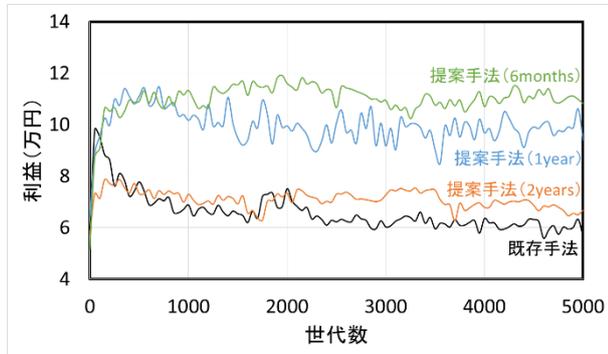


図3 最良個体の利益の世代推移 (ケース 1)

ケース 1 のテスト期間において、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、ケース 1 のテスト期間では成果を上げることが出来ていない。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、ケース 1 のテスト期間では成果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、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ケース 1 の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。また、ケース 1 のテスト期間では、短く分割し学習を行ったものほど利益が上がっており、最も細かく分割した 6ヶ月刻みによる提案手法が最も利益を上げている。

ケース 2 でもケース 1 と同様に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た。

図 4 にその世代で適応度が最も高い個体のケース 3 のテスト期間での利益を示す。この図は、50 試行を平均しており、縦軸は利益(万円)、横軸は世代数を表し、黒線は既存手法の利益、オレンジ線は2年刻みによる提案手法の利益、青線は1年刻みによる提案手法の利益、緑線は6ヶ月刻みによる提案手法の利益を表す。

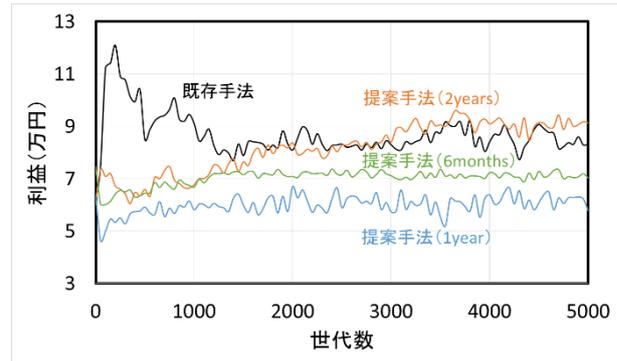


図 4 最良個体の利益の世代推移 (ケース 3)

この期間は強い上昇トレンドの期間であるため上昇トレンドに特化する既存手法が成果を上げることが出来ている。提案手法も学習が進むにつれて利益が上がっているが、6ヶ月刻みと1年刻みによるものは既存手法に劣っている。これは学習期間と同じように提案手法は様々な変動で利益を上げることが出来るように進化しているため、上昇しているところで十分に稼ぐことが出来ていないからだと考えられる。2年刻みによる提案手法は既存手法に勝っている。これは刻み方によって学習させる変動の特徴が異なるため、それがこのテスト期間の変動と合ったからだと考えられる。

4. 今後の課題

本研究では、学習期間を2年、1年、6ヶ月の3種類に区切り学習を行っている。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。そこで、学習期間を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)

アセット・リターン予測 AI とマクロ経済理論の融合 —マルチタスク学習による正則化と識別—

Multi-task learning for asset prices and macro-economy inspired by theory-guided data science

塩野 剛志^{1*}

Takashi Shiono¹

¹クレディ・スイス証券株式会社 経済調査部

¹Economic Research, Credit Suisse Securities (Japan) Limited

Abstract: 本研究では、資産価格リターンの予想を行う Residual Network (ResNet)を、マクロ経済の理論モデル (DSGE) とのマルチタスク学習により正則化する方法を提案する。経済理論が対象とする概念の一部は、現実の資産価格の決定メカニズムにも共有されている。したがって、マルチタスク学習によって共有因子を鮮明化することは汎化性能を改善する可能性がある。そこで、多数の経済金融時系列を入力とし、リターンを予測する ResNet の損失関数に対して、経済理論への整合性が制約となるようなペナルティを課す (正則化項の加算)、というマルチタスク学習を行った。実際、複数のハイパーパラメーターで検証した結果、マルチタスク化によって、テストデータへの汎化性能が改善する傾向が確認された。すなわち、多数の経済金融時系列を教師データとして受け取った AI は、リターン予想に資する特徴の抽出を、経済理論とある程度整合的な仕方で行い、それが過学習の予防となって汎化性能が向上した可能性がある。また、Layerwise Relevance Propagation を応用することで、マルチタスク共有中間層のうち、任意の経済ファクター (DSGE によって識別) と関連の深いユニットを特定し、それらが同時に資産リターンに与えた影響を抽出することで、AI 内部で形成されている経済ファクターと資産価格リターンの相関構造を記述することが可能となり、解釈性を高めることにもなる。

1.はじめに

日本においても、金融データ分析への AI (統計的機械学習) の応用が注目されるようになって数年が経ち、様々な実装が試みられてきただろう。当然のことながら、支配法則が確定しておらず、構造変化に開かれた動的開放システム (結果的に観測データは非定常) である経済金融現象においては、画像・音声認識、囲碁や将棋などと異なり、開発競争の末に圧倒的な性能のモデルがひとつに定まるということは起こりそうにない。どんな実装にも、その時々の相場・経済環境に応じて、実用上の一長一短が残り続けるだろう。本稿では、汎化性の高い予測を、なるべく解釈可能な枠組みで行う、という方向性を重視している。実際、AI の得意とするオルタナティブ・データからの特徴量抽出は、最終的にリターンなどの目標変数の外挿予測・説明に役立たなければ価値を持たないだろう。また、予測に用いることはせず、大量データの要約・解釈だけを追求す

るなら、むやみに複雑化せず、既存のマルチ・ファクターモデルやスタイル分析など線形モデルを使う方が望ましい場合も多い。つまり、常に圧倒的性能を保つ単一のモデル形式を得ることが難しいと思われる以上、AI 的手法を金融経済データの分析に利用するなら、できる限りよい汎化性能と人間による解釈の可能性をバランスを追求すること、が実用上の有益さに資すると考える。今回の分析は、そうした汎化性と解釈可能性 (識別) のバランスを目指した取り組みの一端である。具体的には、ResNet という比較的大きく、表現力の高い (それだけブラックボックス的でもある) 機構の学習に際して、マクロ経済の理論モデルとの整合性という制約を加えることで、中間層を規制し、正則化効果を得ると共に、解釈可能性の向上を図っている。以下では、まず、マルチタスク学習という、同時に複数のタスクに対して学習を進めることで正則化効果を得る枠組みの概略をまとめ (2 章)、続いて、本稿の提案手法である複数アセット・リターンとマクロ経済理論のマルチタスク学習モデルを紹介する (3 章)。その後、マルチタスク学習によって正則化効果が得られるか否かの検証実験を示し (4 章)、最後に、結果の解釈とそれに基づく議論を展開する (5 章)。

^{1*} 連絡先: クレディ・スイス証券株式会社 経済調査部, 〒106-6024 東京都港区六本木 1-6-1 泉ガーデンタワー26 階, Takashi.shiono@credit-suisse.com

2. マルチタスク学習

マルチタスク学習 (Multi-task learning; MTL) は、いくつかのタスクを同時に学習することで、タスク共通の要因を鮮明化し、汎化性能を改善する方法とされ、基本的な文献として [Caruana 97] が挙げられる。この試みが成功する条件 (仮定) は、異なるタスクを代表するデータ変動の説明因子の中に、互いに共有されるものが存在すること、である。

汎化性能が改善する理由としては、(1) 複数のタスクを同時に学習させることで、それらのタスクで共通に有用な特徴が選ばれ易くなる、(2) 各タスクに複数の局所解があるとき、複数のタスクに共通な局所解が選ばれ易くなる、(3) 共通する因子がある複数タスクがあれば、共通因子のノイズがタスク間のキャンセルで緩和される、(4) タスク間で学習の難易度に差があれば、困難なタスクは容易なタスクから情報を得てより簡単に学習可能、などの点が挙げられることが多い。

また、派生的な応用例としては、同じタスクを異なる損失関数を用いて異なるタスクのように学習し、損失関数毎の利点/欠点を補う枠組みや、既に大きなデータセットに対して学習済みのネットワークを新たな特化された目標に対して再学習させる (転移学習) などの枠組みがある。

本稿での取り組みに関して言えば、経済理論が対象とする概念の一部は、金融市場での資産価格決定メカニズムにも共有されているはずである (例えば、CAPM)。したがって、マルチタスク学習によって共有因子を鮮明化することは汎化性能を改善する可能性がある。また、今回のマルチタスク学習によって汎化性能の改善が確認されれば、経済ファンダメンタルズの理解が市場予想に対して無意味でないことの証左ともなり得る。

3. 提案手法

3.1. 概要

本稿の提案手法において、多数の経済金融時系列データを受け取った AI は、リターン予想に資する特徴の抽出を、経済理論とある程度整合的な仕方で行う。すなわち、資産価格リターンの予想を行う ResNet (Residual Network) を、マクロ経済の理論モデル (DSGE) とのマルチタスク学習により正則化する方法を提案する。

具体的には、多数の経済金融時系列を入力とし、リターンを予測する ResNet の損失関数 (メインタスク) に対して、同じ入力から DSGE モデルでマクロ経済変数へフィットする際の損失 (サブタスク)

を、一定の重みで加える、というマルチタスク学習を行う。直感的に言えば、AI は、リターンの予想に資する特徴の抽出を、経済理論とある程度整合的な仕方で行い、それが過学習の予防となって汎化性能が向上する可能性がある。

また、Layerwise Relevance Propagation を応用することで、マルチタスクの共有因子のうち、DSGE で意味特定 (識別) されたファクターに寄与したユニットを分別し、それらが同時に資産リターンに与えた影響を抽出することで、経済ファクターから資産価格リターンへの影響を算出することが可能となり、モデルの解釈性を高めることにもなる。

こうした取り組みは、データサイエンスと科学理論との融合を図る Theory-guided Data Science ([Karpatne et.al. 17]) の考え方に着想を得たものであり、ある意味では、AI の中間層に、理論的な考え方の枠組み、または思考のパターンを、実効的に「埋め込む」試みとも言える。

3.2. Residual Network

使用するデータを所与すれば、最良の性能は十分大きなモデルを適切に正則化できた時に得られるとされる ([Goodfellow et.al. 16])。今回はマルチタスクの共有部分に ResNet を使用しているが、同機構は CNN を多層化した比較的大きなモデルであり、表現力が高く様々な法則 (パターン) を捉えられる。その分、過学習を起こしやすく、正則化の意義は大きいはずである。

ResNet は、[He et.al. 2015]によって提案された畳み込み (Convolution) を多段に重ね、ショートカットを付けたアーキテクチャである。単純に畳み込みを多層にした場合、潜在的な表現力が上がるが、勾配消失で誤差逆伝播が進みづらく実用上の精度が高まらない問題があった。それに対し、ResNet では、ショートカット (ブロックの入力と出力の差分を学習) によって不要な変換をスキップし、教師信号がモデルの端まで伝播しやすくした点が革新的である。

なお、時系列データを時間軸方向に畳み込みすることは、時系列フィルタによる変数変換に相当する。この点、複数チャンネルの $1 \times$ ラグウィンドウ幅の時系列入力に対する ResNet を定義すれば、事実上、不要ならスキップする多段の変数変換を施すことになると言えよう。例えば、「前年比」や「前期比」、「移動平均」などの変数変換も時系列フィルタの一種であり、ResNet を時系列データに用いることは、「前年比の前期差」、「3ヶ月移動平均の3ヶ月前比」などの適切な変数変換を AI が発見し、施してから回帰問題に持ち込むことに相当すると考えられる。

3.3. DSGE モデル

DSGE (Dynamic Stochastic General Equilibrium、動的確率一般均衡) モデルは、観測されるマクロ経済データの変動を、確率 (外生) 的に生じる「構造ショック」が、経済理論に基づく「遷移メカニズム」に沿って伝播した結果と見做す。マクロ経済学研究において一種のベンチマークとなっている標準モデルとして、Smets and Wouters [2007] (以下 DSGE-SW) がある。同モデルでは、マクロ経済には、1) 生産性、2) 家計選好、3) 外生需要、4) 投資効率、5) 物価マークアップ、6) 賃金マークアップ、7) 金融政策という 7 つの「構造ショック」が存在し、それを受けて、マクロ経済の状態を規定する次の 10 個の内生変数が決定されると考える (資本、労働投入、生産、消費、投資、実質資本利回り、実質資本価格、インフレ率、実質賃金、名目金利)。内生変数の遷移・決定メカニズムは、家計 (最終投資家)、労働仲介機関、中間財企業、最終財企業、資本形成部門、中央銀行と政府、という 7 部門の合理的経済主体の最適化行動から導出された構造方程式を対数線形近似したものとしてまとめられる。

内生変数の遷移メカニズムを規定する構造方程式のパラメータは、先行研究の結果を初期分布として採用しつつ、日本、米国、欧州、それぞれの経済データに合うように別途ベイズ推定しておく。こうした構造パラメータは各国のファンダメンタルな経済構造を反映しており、急激な時間変化はしないものと想定されている。なお、具体的な方程式体系と構造パラメータの推定結果については、補論にまとめている。

構造パラメータを所与とすれば、DSGE の対数線形化された構造方程式体系を内生変数について解くことで²、次式のような誘導形の線形状態空間システムが得られる。

$$U_t = FS_t,$$

$$S_{t+1} = PS_t + z_{t+1}$$

行列 F : 状態変数 S ⇒ 内生変数 U

行列 S : 構造ショック z を受けた状態変数 S の遷移

すなわち、DSGE モデルは、前期の状態変数を既知とした上で、今期の構造ショックを今期の経済データへと変換する行列に集約される。したがって、パラメタライズされた DSGE-SW の誘導形は、意味特定された構造ショックに相当する 7 次元の入力を受け取って経済データを出力する一種のニューラルネットワークのレイヤーと見做すことができる。後

² 実装には[Klein 00]の方法を用いた。

述するように、本稿では ResNet のサブタスクにおける出力層として日、米、欧それぞれの DSGE-SW の誘導形を実装している。

3.4. アーキテクチャと具体的な実装

改めて提案手法のアーキテクチャを見取り図で示せば図 1 のようになる。ResNet を共有ブロックとしたマルチタスク構造であり、メインタスクを複数資産リターンの 1 期先予想、サブタスクを DSGE レイヤーによるマクロ経済変数へのフィット、とした回帰問題である。入力データは、共有部の ResNet で変換された後、出力層に至る前に、タスク固有の中間層と教師なし中間層へと伝搬される。ここで、教師なし中間層は、入力データに含まれるが、どのタスクにも明確に寄与せず、かつ、ノイズとしてはキャンセルされなかったような残差的パターンを吸着しておく役割を期待したものである。

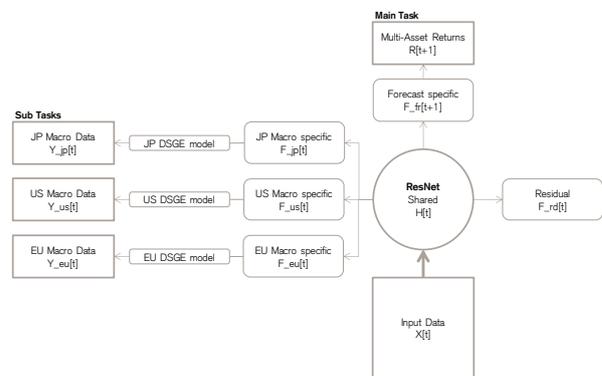


図 1 : 提案手法のアーキテクチャ

具体的な実装として、共有部の ResNet ブロックは、入力段階の Convolution1 層に加え、3 層のボトルネック型 ResNet ブロックを 4 つ重ねた 13 層構造。さらに、共有部からの出力は、各タスク固有の中間 1 層と各タスク固有の出力 1 層へと伝播し、全体の深さは計 15 層である³。

また、経済金融時系列データの 1 期分を X_t 、一度に入力するラグ期間の幅を W として $([X_{t-W}, \dots, X_t])$ 、初期 Convolution 層に入力する 1 単位 (バッチサイズ $b = 1$) の入力データは、たてよこ $1 \times W$ サイズで、チャンネル数が $\dim(X_t)$ のテンソル $(b, 1, W, \dim X_t)$ とする。

この設計において、畳み込みカーネルは時間 W 方向を走査することになり、前述の通り、個々の時系列データはフィルタリングによって変数変換され

³ 利用可能な計算資源、並びに、データ・サンプル数の限界を考慮して、ボトルネック型 ResNet ブロックの積層数は最小限にしており、ResNet 構造の実装としては小さい部類である。

ることになる。ResNet では、ブロック内でチャンネル次元の圧縮・拡張を繰り返すが、ここでは、チャンネル圧縮係数 (K) を定義し、これが大きいほど最大チャンネルサイズ ($\dim(X_t)/K$) が小さくなるように設計した。また、アーキテクチャに含まれる未知パラメータの学習は、アセット・リターン予想のバッチ平均二乗誤差に、日本、米国、欧州の DSGE による経済データ・フィットの二乗誤差を、ペナルティ・ウェイト (A) を乗じた上で加算した損失関数を最小にするように進められる。

この際、入力データとリターンの教師データは週次を用いるが、マクロ経済データは四半期ベースの DSGE を通じてフィットさせるため、データ観測周期のマッチングをする必要がある。これには、モデル全体の訓練ミニバッチのサイズを 1 四半期分にする (バッチサイズ=約 13 週) ことで対応した。すなわち、ResNet を通じた構造ショックの週次理論値を DSGE レイヤーに入力すると、経済データの週次理論値が出力されるが、それをバッチ平均することで四半期ベースの理論値とし、マクロ経済データの四半期実績値との誤差を取る。そして、メインタスクである週次アセット・リターン予測誤差のバッチ平均 (四半期分) に、同期の経済データ誤差を加算したものを全体の損失関数として学習する。

以上の実装のもとで、探索するハイパー・パラメータは、畳込層のチャンネル圧縮係数 (K)、入力データのラグウィンドウ幅 (W)、DSGE ペナルティ・ウェイト (A)、の 3 つとする。なお、その他の設定として、最適化は Adam を使い、Epoch 数は Early Stopping により決定している。

3.5. 使用データ

今回使用した入力データは、次の国・地域について、ブルームバーグの<ECST>に掲載された「主要経済指標」(日、米、欧、英、豪、中、韓、台、印、タイ、インドネシア、ベトナム、ロシア、トルコ、南ア、ブラジル、メキシコ)、及び、その他グローバル金融指標、国際コモディティ市況 (CRB 内訳)、先進国セクター別株価指数、スマートベータ、クレジット指数、クロスカレンシー・スワップ等、計 2,036 系列である。

また、出力 (教師) データについて、メインタスクであるマルチ・アセットリターンは、クレディ・スイス計算による次の先進国株式と債券の先物インデックス (SP500 先物、DAX 先物、日経 225 先物、FTSE100 先物、米 10 年債先物、独 10 年債先物、日 10 年債先物、英 10 年債先物) と、為替レート (ドル円、ユーロ円、ポンド円) の週次変化率 (リターン)、計 11 系列である。

マクロ経済データについては、DSGE の内生変数と整合的になるように、日本、米国、欧州、それぞれの実質 GDP、消費、投資、労働投入、インフレ率、実質賃金、政策金利の 7 系列のデータを用いた。

なお、全サンプル期間は 2001 年 1 月第 1 週～2018 年 7 月最終週までである。

4. 正則化効果の検証実験

4.1. 性能評価の枠組み

ハイパー・パラメータの違いによる汎化性能の差を検証するため、性能評価の枠組みを設定する。今回は、複数テスト期間の平均パフォーマンスで評価する。なお、交差検証を用いる考え方もあるが、時系列データの予想問題においては、未来のデータで学習したパラメータを用いて過去を予想するテストになってしまうことから行わない。

具体的には、共通訓練期間を 2001～2007 年とし、その後 3 年ずつ訓練データを追加して 4 回バックテスト (テスト終点はいずれも 2018 年 3 月末週) を行う (テスト期間: ①2008～、②2011～、③2014～、④2017～)。このため、新たにデータを追加 (局面が変化) しても、高精度を維持したモデルが高評価となり、一時的によく当たっただけのモデルは評価されにくい。

また、パフォーマンスの評価尺度は、標準化 (z 変換) した 11 資産のリターン (週次) の平均絶対予測誤差 (MAE) とする。

4.2. ランダムサーチによる検証

ハイパー・パラメータ探索にはランダムサーチを用いた。すなわち、ハイパー・パラメータの組み合わせを探索区間から乱数発生させて指定した。今回は 310 セットの乱数を発生させた。そのうち 40 は、経済データとのマルチタスク学習によるリターン予想問題の正則化効果の有無を図るのが目的のひとつであるため、ペナルティ・ウェイト (A) を 0 に固定してコントロール・グループとした。

ランダムサーチを行い、前述の 4 回バックテストの平均絶対誤差 (MAE) でそれぞれのハイパー・パラメータの下でのモデルを評価した結果は、図 2、図 3、図 4、の通りとなった。すなわち、畳込層のチャンネル圧縮係数 (K) は、0.3 と、2.5～3.0 範囲の 2 極で誤差が低下する傾向が見られた。また、入力データのラグ・ウィンドウ幅 (W) は、10～20 の範囲で誤差が低下する傾向にあった。肝心の DSGE ペナルティ・ウェイト (A) は、0.6～0.7 の範囲で誤差が低下する傾向が示された。

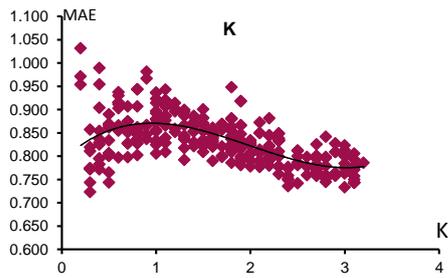


図 2 : K を指定した場合の MAE の分布

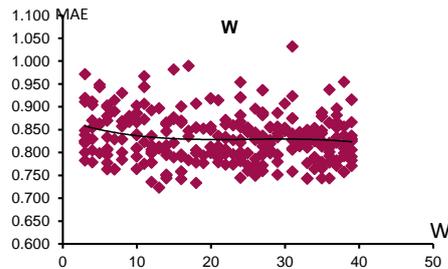


図 3 : W を指定した場合の MAE の分布

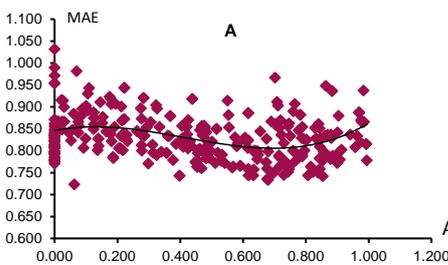


図 4 : A を指定した場合の MAE の分布

4.3.DSGE ペナルティによる正則化効果

改めて、DSGE ペナルティ・ウェイト (A) が 0 のケース (他のパラメータはランダム) について、前述の 4 回バックテストでの z 変換 11 資産平均絶対誤差 (MAE) の平均を計算すると、0.834 であった。他方、DSGE ペナルティ・ウェイト (A) が 0.6 以上 0.7 以下の場合、同テスト値は 0.795 であった。すなわち、経済理論 (DSGE) ペナルティによって、確かにリターン予想の汎化性能は向上しており、正則化効果が確認された (図 5)。

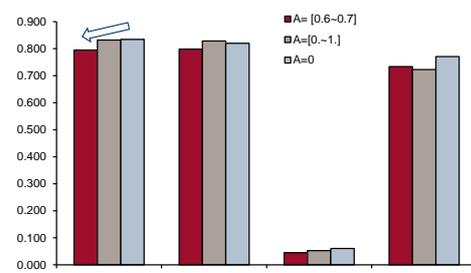


図 5 : A の領域別 MAE 分布の各種記述統計

ちなみに、「超過単位リスク当たりリターン」を評価尺度とした場合、最も優れていたスペックは $K=2.3$ 、 $W=26$ 、 $A=0.57$ であった。この評価尺度は、AI による予測をシグナルとして利用し、対象の 11 資産について上昇予想ならロング (1)、下落予想なら 0 というポジションを取る単純なローテーション戦略のシャープレシオから、ベンチマークとして全 11 資産を全期間ロングするポジションのシャープレシオを引いた値である。もっとも、そのスペックでの実際の評価値 (超過シャープレシオの 4 回バックテスト平均) は年率換算で +0.14 と小幅であった (4 回テスト期間のシャープレシオの平均は AI シグナル運用で +0.87、ベンチマークで +0.73)。

5. 結果の解釈とモデルの副次的利用

5.1. 正則化効果の解釈

以上の検証の結果、DSGE を通じた経済データ説明とのマルチタスク化によって、複数資産のリターン予想における汎化性能が改善する傾向が示された。すなわち、多数の経済金融時系列を教師データとして受け取った AI は、リターン予想に資する特徴の抽出を、経済理論とある程度整合的な仕方で行い、それが過学習の予防となって汎化性能が向上した可能性がある。すなわち、深層学習の表現力の高いアーキテクチャでは、局在的 (時系列データで言えば短期的) にしか成立しないノイズのようなパターンであっても、訓練データにおける誤差低減への寄与が大きかったものなら重きを置いて学習してしまう。それに対して、経済理論をパラメータ学習の制約条件 (ガイド) として与えた場合、より普遍性のある特徴の抽出が喚起され、結果的に、まだ見ぬサンプルに対する予測力の向上に繋がったと考えられる。

また、マルチタスク学習による正則化が成功する条件は、異なるタスクを代表するデータ変動の説明因子の中に、互いに共有されるものが存在すること、であった。したがって、今回の結果は、経済ファンダメンタルズ理解が市場予想に対して無意味でないことの証左とも言える。資産価格の変動要因として、マクロ経済に関するファンダメンタル・リスクファクター (経済ファクター) が、確かに内在している。それを積極的に予想して投資機会とするか、または、予想を控え、複数の経済ファクターに分散投資して回避するかは戦略次第だが、いずれにせよ、AI であろうとなかろうと、マクロ経済ファクターへの理解が運用パフォーマンス向上に資する可能性が示唆されたと言える。

5.2. マルチタスクによる学習へのガイド

直感的に言えば、本稿提案手法において、AI は入力に対してどう反応すべきかのガイドを与えられた上で予想を作成している。つまり、既に普遍性や有用性が確認されている考え方の枠組み（理論）や思考パターン（経験則）を AI の中間層へ「埋め込んで」いる」との表現も可能であろう。

こうした「中間層形成に対する思考のガイド」が経済理論である必然性はなく、また、予測対象がマクロの資産インデックスである必要もない。例えば、決算情報やテキストデータを入力とし、「典型的な運用スタイル」や「著名投資家の行動履歴」をガイドにした上で、個別株のストック・ピックを行うような判別問題のアーキテクチャを構築してもよいだろう。

5.2. 経済ファクターとリターンの関係を識別

続いて、経済理論をガイドとしたマルチタスク学習の副次的な利点として、経済ファクターと資産リターンとの関係性のある程度識別することができる。繰り返しとなるが、マルチタスクによる正則化効果があったということは、リターン予想と経済ファンダメンタルズに共有因子あることを意味する。

そのため、LRP (Layerwise Relevance Propagation)⁴を用いて、マルチタスク共有因子のうち、それぞれの経済ファクター (=DSGE 構造ショック) の出力に寄与したユニットを絶対値でランキングする (今回は上位 5%のみ指定)。これによって、その経済ファクターと関連の深い共有部ユニットがどれかを識別することができる。ひとたび共有部における任意の経済ファクターとの関連ユニットが特定されれば、入力データに対して、その関連ユニットのみを使用して予想リターンを出力することで、予想リターンのうち、ある経済ファクターとの関連が特定された成分を生成することができる (図 6)。

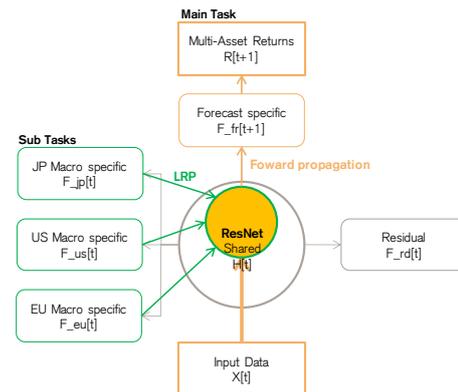


図 6: サブタスクに関連するユニットの特定と使用

なお、こうした識別の作業を行う際には、直近までのデータを全て訓練データとして学習させ、出力は全てインサンプル理論値となっている。また、ハイパー・パラメーターは $K=0.3$, $W=15$, $A=0.6$ を選択している。計量経済学では全サンプルを使用した線形回帰を使って変数間の関連識別を行うことが多いが、今回の作業は同様の発想を大規模データとニューラルネットの下で実装する工夫であると言える。

実例として、入力データを受け取った AI の共有中間層 (脳のようなもの) のうち、主として米国の家計リスク選好ファクターに関連することが分かっているユニット (脳の領域) のみを活性化して出力した米国株価リターンの成分は、図 7 のように示される。

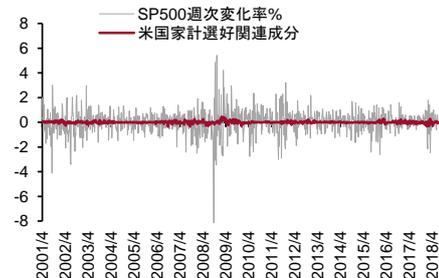


図 7: 米国家計選好関連ユニットによる米株リターンの理論値

また、このように識別した各経済ファクターの各資産リターンへの影響成分 (識別ユニット出力) と、実際の各資産リターンの実績値との相関を示したのが図 8 である (2002~2017 年)。全ユニットの上位 5% という限られた情報のみを活性化して得た成分であるため、リターン実績全体の動きと比べた相関係数の値は小さくなりがちだが、資産クラス毎の各ファクター間の相対順位には意味がありそうだ。例えば、今回の AI は、訓練期間の学習の結果、米国株価の変動予想について、「米国家計のリスク選好」ファクターと、「米国の物価マークアップ」ファク

⁴ LRP は出力結果に対する入力データの寄与度を、推定済みのニューラルネットワークを出力層から逆に遡及計算していく手法である。詳しくは [Binder et al. 16] を参照されたい。

ターが特に正相関していると判断していた。

	JP				US				EU			
	zA	zB	zI	zP	zA	zB	zI	zP	zA	zB	zI	zP
SP500先物	0.01	0.02	0.03	-0.03	0.01	0.03	0.08	-0.01	0.08	0.05	0.02	0.08
日経225先物	0.01	0.00	0.03	0.04	0.03	0.00	0.04	0.00	0.01	0.01	0.04	0.02
DAX先物	-0.04	-0.02	0.00	-0.02	0.00	-0.04	-0.04	-0.04	0.01	0.00	0.03	0.00
FTSE100先物	0.02	0.03	0.03	0.04	0.01	0.03	0.04	0.01	0.02	0.02	0.03	0.01
米10年債先物	0.00	0.03	0.01	0.05	0.04	0.02	0.05	0.03	0.04	0.05	0.04	0.00
日10年債先物	0.07	0.05	0.09	0.05	0.06	0.07	0.02	-0.01	0.08	0.03	0.02	0.06
独10年債先物	0.07	0.02	0.03	0.07	0.05	0.01	0.07	0.05	0.03	0.07	0.04	0.08
英10年債先物	0.03	0.07	0.00	-0.02	-0.04	0.03	0.01	0.04	0.02	0.04	0.05	-0.03
ドル円	0.05	0.06	0.03	0.03	0.08	0.07	0.07	0.06	0.05	0.07	0.02	0.05
ユーロ円	-0.01	-0.02	-0.01	0.01	0.00	0.00	-0.03	-0.04	0.00	-0.02	-0.01	-0.03
ポンド円	0.04	0.03	0.01	0.05	0.00	0.01	-0.03	-0.03	0.00	0.03	0.01	0.00
生産性 (zA)												
家計選好 (zB)												
外生需要 (zI)												
投資効率 (zP)												
物価マークアップ (zW)												
賃金マークアップ (zX)												
金融政策 (zR)												

図 8：識別ユニット出力と各資産リターンの実績値との相関構造

また、AI のアウトオブ・サンプル予想が外れた場合に、原因究明が求められることがある。その際は、ある資産クラスについて、アウトオブ・サンプル出力における各経済ファクターとの相関構造と、改めて全データで AI を訓練し直した場合のインサンプルでの相関構造との差を見ることで、過去のデータからは獲得できていなかったサプライズなパターンがどの経済ファクターについて生じたのか、までは識別することができよう（例えば、訓練期間では米国株に米国生産性はあまり効いていなかったのに、テスト期間では予想外に強く効き始めてしまったために予測精度が低下した、などと記述が可能）。

さらに、こうしたインサンプル推計による識別ユニット出力を使って、過去局面毎に、経済ファクターと資産リターンとの関係性がどう変化してきたかを確認することもできる。例えば、図 8 は、米国家計選好の改善シグナルで米株をロング、悪化シグナルでショートした場合の累積リターン（＝米国家計選好ファクター・プレミアム）と、米国物価マークアップの上昇シグナルで米株をロング、悪化シグナルでショートした場合の累積リターン（＝米国物価マークアップ・ファクター・プレミアム）を示したものである。累積リターンが拡大している期間は、米国家計のリスク許容度が改善すれば株価が上昇するという理論的に期待される関係が正常に機能していた期間であり、累積リターンが縮小している期間はその法則が機能しなくなった期間（ある種の異常性の検知）と解釈できる。



図 8：経済ファクター・プレミアムの例

5.3. ナウキャスト

最後に、本稿提案アーキテクチャの別の副次的な利用として、サブタスクの出力による経済データのナウキャストが可能である。同 AI のアウトオブ・サンプル期間におけるサブタスク出力は、各時点で利用可能な入力データを用いて、その時点が含まれる四半期のマクロ経済データの状態を週次で推定したものととなる。これは、最新時点での入力データで変動が分かっている金融データや高頻度の先行指標などから、発表ラグのある GDP を中心とした出力側のマクロ経済データを推定したナウキャスト値としてそのまま利用可能である（図表 9、10）。これは、マーケットが大量情報を消化して資産価格を変化させるプロセスを追うことで、そこで想定されているマクロ経済要因の変化を察知するプロセスと言える。

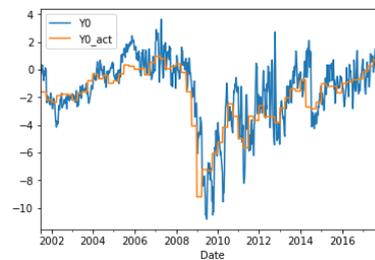


図 9：日本実質 GDP（対数・線形トレンド除去%）：内挿理論値

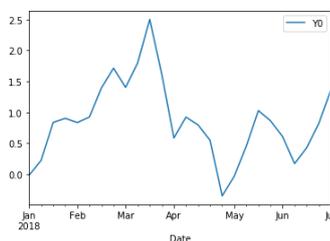


図 10：同・外挿予想値

参考文献

[Binder et al. 16] Binder, A. "Layer-wise Relevance Propagation for Neural Networks with Local Renormalization Layers", arXiv:1604.00825 (2016).

[Caruana 97] Caruana, R. "Multitask Learning", Machine Learning, vol.28 (1997).

[Goodfellow et al. 16] Goodfellow, I. et al. "Deep Learning", MIT Press (2016).

[He et al. 2015] Kaiming, H. et al. "Deep Residual Learning for Image Recognition," arXiv:1512.03385 (2015).

[Karpatne et al. 17] Karpatne, A. et al. "Theory-Guided Data Science: A New Paradigm for Scientific Discovery from Data," IEEE Transactions on Knowledge and Data Engineering, vol. 29, no. 10,

pp. 2318-2331, (2017). doi: 10.1109/TKDE.2017.2720168

[Klein 00] Klein, P. "Using the generalized Schur form to solve a multivariate linear rational expectations model", Journal of Economic Dynamics and Control vol. 24 No.10, pp.1405-1423 (2000).

[和泉 03] 和泉 潔: 人工市場—市場分析の複雑系アプローチ, 森北出版 (2003).

https://www.morikita.co.jp/books/book/2239

補論

(1) DSGE-SW の構造形方程式 (線形近似)

[SW1] 資本成長

$$K_t = (1 - \tau)K_{t-1} + \tau I_t + \tau(1 + \beta)S^m \epsilon_t^I,$$

[SW2] 労働需要

$$L_t = -w_t + \left(1 + \frac{1}{\psi}\right)r_t^k + K_{t-1},$$

[SW3] 資源制約

$$Y_t = C_t + I_t + \frac{r^k K_t}{\psi} + \epsilon_t^C,$$

[SW4] 生産関数

$$Y_t = \phi \epsilon_t^a + \phi \alpha K_{t-1} + \frac{\phi \alpha}{\psi} r_t^k + \phi(1 - \alpha)L_t,$$

[SW5] 一般化テイラールール

$$R_t = \rho R_{t-1} + (1 - \rho)[r_{\pi 1} \pi_t + r_{y 1} Y_t + r_{\pi 2} \pi_{t-1} + r_{y 2} Y_{t-1}] + \epsilon_t^r,$$

[SW6] 消費遷移式

$$C_t = \frac{h}{1+h} C_{t-1} + \frac{1}{1+h} E_t[C_{t+1}] - \frac{1-h}{(1+h)\sigma_c} (R_t - E_t[\pi_{t+1}]) + \epsilon_t^b,$$

[SW7] 投資遷移式

$$I_t = \frac{1}{1+\beta} I_{t-1} + \frac{\beta}{1+\beta} E_t[I_{t+1}] + \frac{1}{(1+\beta)S^m} q_t + \epsilon_t^I,$$

[SW8] 資本価格決定式

$$q_t = -(R_t - E_t[\pi_{t+1}]) + \frac{1 - \tau}{1 - \tau + r^k} E_t[q_{t+1}] + \frac{r^k}{1 - \tau + r^k} E_t[r_{t+1}^k],$$

[SW9] 物価フィリップス・カーブ

$$\begin{aligned} \pi_t &= \frac{\beta}{1 + \beta t_p} E_t[\pi_{t+1}] + \frac{t_p}{1 + \beta t_p} \pi_{t-1} \\ &+ \frac{(1 - \beta \xi_p)(1 - \xi_p)}{(1 + \beta t_p) \xi_p} (\alpha r_t^k + (1 - \alpha)w_t - \epsilon_t^a) \\ &+ \epsilon_t^p, \end{aligned}$$

[SW10] 賃金フィリップス・カーブ

$$\begin{aligned} w_t &= \frac{\beta}{1 + \beta} E_t[w_{t+1}] + \frac{1}{1 + \beta} w_{t-1} + \frac{\beta}{1 + \beta} E_t[\pi_{t+1}] + \frac{1 + \beta t_w}{1 + \beta} \pi_t \\ &+ \frac{t_w}{1 + \beta} \pi_{t-1} \\ &- \frac{(1 - \beta \xi_w)(1 - \xi_w)}{(1 + \beta) \left(1 + v_l \frac{1 + \lambda_w}{\lambda_w}\right) \xi_w} (w_t - v_l L_t) \\ &- \frac{\sigma_c}{1 - h} (C_t - h C_{t-1}) + \epsilon_t^w, \end{aligned}$$

[AR1] 生産性ショックの AR(1)過程

$$\epsilon_t^a = \rho_a \epsilon_{t-1}^a + z_t^a,$$

[AR 2] 選好ショックの AR(1)過程

$$\epsilon_t^b = \rho_b \epsilon_{t-1}^b + z_t^b,$$

[AR 3] 外生需要ショックの AR(1)過程

$$\epsilon_t^c = \rho_c \epsilon_{t-1}^c + z_t^c,$$

[AR 4] 投資効率ショックの AR(1)過程

$$\epsilon_t^d = \rho_d \epsilon_{t-1}^d + z_t^d,$$

[AR 5] 物価マークアップ・ショックの AR(1)過程

$$\epsilon_t^e = \rho_e \epsilon_{t-1}^e + z_t^e,$$

[AR 6] 賃金マークアップ・ショックの AR(1)過程

$$\epsilon_t^f = \rho_f \epsilon_{t-1}^f + z_t^f,$$

[AR 7] 金利環境 (裁量金融政策) ショックの等号

$$\epsilon_t^r = z_t^r,$$

内生変数		外生 AR (1) 過程		構造ショック	
K_t	資本	ϵ_t^a	生産性	z_t^a	生産性ショック
L_t	労働投入	ϵ_t^b	選好	z_t^b	選好ショック
Y_t	生産	ϵ_t^c	外生需要	z_t^c	外生需要ショック
r_t^k	実質資本利回り	ϵ_t^d	投資効率	z_t^d	投資効率ショック
R_t	名目金利	ϵ_t^e	物価マークアップ	z_t^e	物価マークアップ・ショック
C_t	消費	ϵ_t^f	賃金マークアップ	z_t^f	賃金マークアップ・ショック
I_t	投資	ϵ_t^r	金利環境	z_t^r	金利環境ショック
q_t	実質資本価格				
π_t	インフレ率				
w_t	実質賃金				

(2) DSGE-SW の構造パラメータ推定結果

パラメータ 役割	事前分布	推定結果 (事後分布平均)			
		形状	平均	標準偏差	95% 区間
経済構造パラメータ					
α	資本係数 (分配率)	外生	-	0.30	0.30
β	主観的時間割引率	外生	-	0.99	0.99
τ	資本減耗率	外生	-	0.03	0.03
λ_w	賃金マークアップ係数	外生	-	0.30	0.30
ψ	資本稼働コスト	ベータ	0.35	0.08	0.38
t_p	物価のインデジゼーション度	ベータ	0.26	0.15	0.34
t_w	賃金のインデジゼーション度	ベータ	0.22	0.15	0.29
ξ_p	Calvo の価格硬直性	ベータ	0.84	0.1	0.86
ξ_w	Calvo の賃金硬直性	ベータ	0.85	0.15	0.92
v_l	労働の CRRA 係数	ガンマ	2	0.15	2.11
σ_c	消費の CRRA 係数	ガンマ	1.7	0.15	1.81
h	慣性形成度	ベータ	0.69	0.1	0.68
φ	生産の固定費用	ベータ	0.45	0.1	0.52
S^m	資本調製コスト係数	正規	5.3	1	5.30
政策反応パラメータ					
$f_{\pi 1}$	現在インフレへのテイラールール係数	ガンマ	2.2	0.1	2.31
$f_{y 1}$	現在生産へのテイラールール係数	ベータ	0.35	0.1	0.40
$f_{\pi 2}$	過去インフレへのテイラールール係数	正規	-0.22	0.1	-0.22
$f_{y 2}$	過去生産へのテイラールール係数	正規	-0.08	0.1	-0.03
ρ	名目金利の自己回帰係数	ベータ	0.87	0.1	0.92
外生ショックパラメータ					
ρ_a	生産性 AR(1)過程の自己回帰係数	ベータ	0.91	0.1	0.92
ρ_b	選好 AR(1)過程の自己回帰係数	ベータ	0.77	0.1	0.95
ρ_c	外生需要 AR(1)過程の自己回帰係数	ベータ	0.9	0.1	0.76
ρ_d	投資効率 AR(1)過程の自己回帰係数	ベータ	0.71	0.1	0.94
ρ_e	物価マークアップ AR(1)過程の自己回帰係数	ベータ	0.82	0.1	0.77
ρ_f	賃金マークアップ AR(1)過程の自己回帰係数	ベータ	0.52	0.1	0.83
構造ショックの標準偏差					
σ_a	生産性ショックの標準偏差	逆ガンマ	0.1	0.5	0.82
σ_b	選好ショックの標準偏差	逆ガンマ	0.1	0.5	0.83
σ_c	外生需要ショックの標準偏差	逆ガンマ	0.1	0.5	0.79
σ_d	投資効率ショックの標準偏差	逆ガンマ	0.1	0.5	0.81
σ_e	物価マークアップ・ショックの標準偏差	逆ガンマ	0.1	0.5	0.79
σ_f	賃金マークアップ・ショックの標準偏差	逆ガンマ	0.1	0.5	0.81
σ_r	裁量金融政策ショックの標準偏差	逆ガンマ	0.1	0.5	0.81

人工知能を用いた株価下落リスクの予兆管理

Early Warning System for Equity using Artificial Intelligence

石原 龍太*
Ryota Ishihara

株式会社かんぽ生命保険 運用企画部
Investment Planning Department, JAPAN POST INSURANCE Co., Ltd.

Abstract: In This paper, I propose a method to use Artificial Intelligence for early warning in TOPIX trading. I construct an early warning system with AI that includes AI traders who preliminarily learned TOPIX market data, and by using forecast of AI traders as early warning indicators, efficiency of scoring the indicators has been improved. In addition, I conducted a TOPIX trading simulation using the early warning system with AI, which resulted in a higher Sharpe ratio than that of TOPIX.

1 はじめに

資産運用では、資産価格変動リスクに対して機動的かつ的確に対処するために、市場環境の大きな変化の予兆を察知できることが望ましい。近年、金融機関の市場部門やリスク管理部門において、資産価格変動リスクを適切に制御する「予兆管理」と呼ばれる取り組みが広がりつつある。

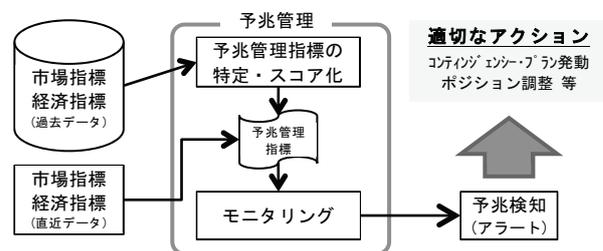
資産運用における予兆管理とは「将来の資産価格変動につながり得る市場の兆候を体系的に検知し、適切なアクションに繋げる試み」であり、予期せぬ資産価格変動による損失を回避・軽減させる目的で取り組まれている。特にリスク管理の観点では、テールリスク¹顕在化時における会議の招集やポジションリミットの発動といったコンティンジェンシー・プラン²発動のトリガーとしての活用が期待されている。

資産運用における予兆管理は、①市場指標や経済指標等の様々なデータから、将来の資産価格変動に先行して反応すると思われる予兆管理指標を特定～スコア化する、②予兆管理指標を継続的にモニタリングし、資産価格変動の兆候を検知する、という2つのプロセスで構成される。このうち、①の予兆管理指標の特定・スコア化のプロセスでは、分析に関する高度な知見を有するクオンツと呼ばれる分析担当者が、理論的・経験的に想定される因果関係や相

関関係に基づいて数理モデルを作成することが一般的である。

しかし、実務での運用に耐えうる予測精度をもつ数理モデルの作成は容易ではなく、また、そのような優れた数理モデルの詳細が、相応の対価なしに開示されることはまずない。ゆえに今後、広く資産運用の現場に予兆管理が浸透していくためには、クオンツによる専門的な分析や数理モデル作成を必要としない予兆管理の手法が求められるものと考えられる。そこで本稿では、システムの異常検知における事例³を参考に、株式の予兆管理に人工知能（以下、AI）を用いる手法を提案する。具体的には、AIが株価下落に係る予兆管理指標の特定・スコア化を行うシステム（以下、AI予兆管理システム）を構築し、当該

図1 資産運用における予兆管理フロー



(出所) 筆者作成。以下同じ。

* 連絡先: ryouta.ishihara.hw@jp-life.jp

¹ まれにしか起こらないはずの想定外の暴騰・暴落が実際に発生するリスク。通常は暴落リスクを指す。

² 起こりうる不測の事態、最悪の事態を事前に想定し、あらかじめ策定しておく対応策や行動手順。

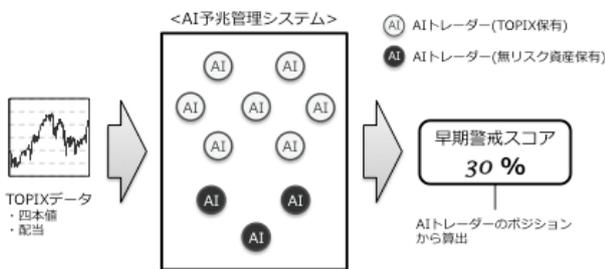
³ システムの異常検知の分野では、監視アラートの閾値やルール設定といった、これまで属人的に行っていたプロセスに人工知能を用いる研究がなされている。

システムを用いて株価の下落リスクの予兆管理を試みるものである。

2 AI 予兆管理システム

本稿では、図2に示すAI予兆管理システムを構築し、TOPIXが下落する兆候の検知を試みる。当該システムは、「TOPIX」と「無リスク資産」を投資対象とする10個体のAIトレーダーから構成され、その投資行動から算出する早期警戒スコアを予兆管理指標として用いることで、TOPIX下落の兆候を可視化するものである。

図2 AI予兆管理システムの概要

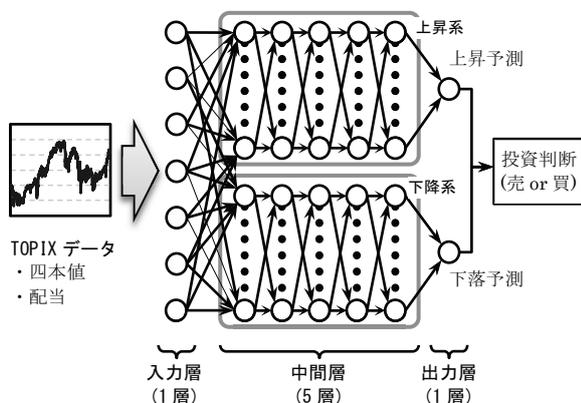


2.1 AI トレーダー

2.1.1 AI トレーダーの作成

AI予兆管理システムに組み入れるAIトレーダー k ($k=1, 2, \dots, 10$)は、石原(2017)のAI運用モデル(図3の投資判断アルゴリズムをもつAIトレーダー)を

図3 AIトレーダーの投資判断アルゴリズム



(注) 丸はノード、矢印はノード間の結合と処理の流れを示す。

(出所) 石原(2017) (筆者により一部修正)

用いて作成する。

当該AIトレーダー k は、知覚した市場データ t を基にTOPIXの価格変動を予測し、当該予測結果を踏まえてポジションの調整(TOPIX上昇を予測: TOPIXを保有, TOPIX下落を予測: 無リスク資産を保有)を行うものとする。

2.1.2 AI トレーダーの最適化

2005年1月~2014年12月の市場データから学習データと検証データを設定し、前項で作成したAIトレーダー k について、「学習⁵」、「検証⁶」の2ステップにより、市場データに対して高い適合度が得られる投資判断アルゴリズムを決定する。このとき、表1の期間の市場データを学習データ、2005年1月~2014年12月の市場データを検証データとし、各AIトレーダーの適合度には表2の指標を用いるものとする。

なお、学習データに対する過剰適合を避けるため、

表1 各AIトレーダーの学習データ

k	期間
1, 6	2007年~2014年
2, 7	2005年~2006年, 2009年~2014年
3, 8	2005年~2008年, 2011年~2014年
4, 9	2005年~2010年, 2013年~2014年
5, 10	2007年~2012年

表2 適合度に用いる指標

k	適合度の指標
1~5	インフォメーションレシオ ⁷
6~10	シャープレシオ ⁸

⁴ 市場データの定義は、石原(2017)の市場データ(日次のTOPIX四本値データと配当データ)と同じものとする。

⁵ 学習データに対する適合度を最大化する投資判断アルゴリズムのネットワーク構造を、遺伝的アルゴリズムを用いて10000回探索する。このとき、適合度を除く遺伝的操作のパラメータは、石原(2017)と同じものを用いる。

⁶ 学習ステップのネットワーク探索において、各回の適合度が最大となったネットワーク構造から、検証用データに対する適合度が最も高いものを選択する。

⁷ 「ベンチマークに対する月次超過収益率の平均÷月次超過収益率の標準偏差」の式で算出。

⁸ 「月次収益率の平均÷月次収益率の標準偏差」の式で算出。

学習ステップでは、確率的に選別した時点における出力層ノードの値を反転 (0→1, 1→0) させる⁹ものとする。

2.2 早期警戒スコアの算出

TOPIX が下落する兆候を可視化するため、予兆管理指標である早期警戒スコアを日次で算出する。時点 t における早期警戒スコア x_t は以下のように表現する。

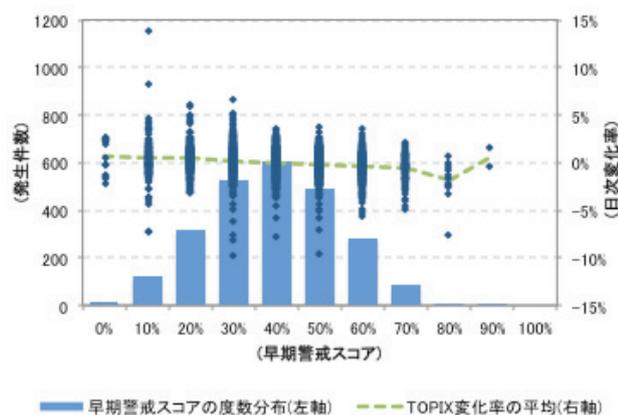
$$\text{早期警戒スコア}_t = 1 - \frac{x_{1t} + \dots + x_{10t}}{10}$$

このとき x_{kt} の値は、時点 t における AI トレーダー k のポジション (TOPIX を保有する場合は $x_{kt}=1$, 無リスク資産を保有する場合は $x_{kt}=0$) とする。

2.3 早期警戒スコアの分析

2005年1月～2014年12月における早期警戒スコアとその翌営業日の TOPIX 変化率の関係を図4に示す。早期警戒スコアは40%を中心に分布しており、翌営業日の TOPIX 変化率は早期警戒スコアが高いほど低いという傾向が見られる。早期警戒スコアが50%未満のグループと50%以上のグループについて、翌営業日の TOPIX 日次変化率を比較すると、図5の

図4 早期警戒スコアと翌営業日の TOPIX 変化率の分布 (2005年～2014年)



⁹ 当該処理はドロップアウトの手法を参考としたものである。時点の選別は上昇系と下降系で別々に行い、各時点が選別される確率は3%とする。また、遺伝的操作100回毎に適合度の値を再計算(時点の再選別)することで、偶然の要素により精度の低い個体が高い適合度を得るリスクを低減する。

とおり、早期警戒スコアが50%以上のグループのほうが、翌営業日の TOPIX が下落する確率が高いことがわかる。このことから、TOPIX が下落する兆候については、早期警戒スコアの水準により一定程度捉えることができるものと考えられる。

また、テールリスクが顕在化¹⁰する直前(前営業日)の早期警戒スコアは、図6のとおり10%～80%と広範囲に分布していることがわかる。このことから、テールリスク顕在化の兆候については、早期警戒スコアの水準により判別することができないものと考えられる。

これらの結果から、AI 予兆管理システムは「TOPIX が下落する兆候を検知する性能は有しているものの、テールリスク顕在化の兆候の検知する性能までは有していない」と判断する。

図5 TOPIX 日次変化率の確率分布図 (2005年～2014年)

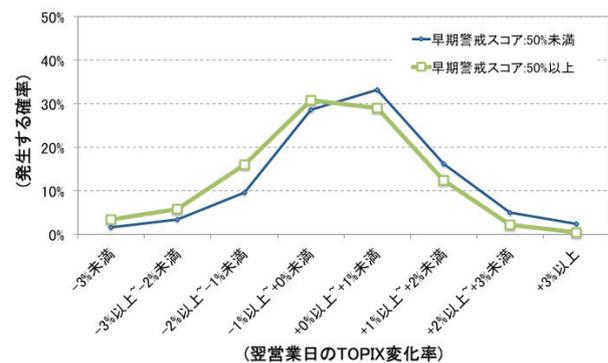
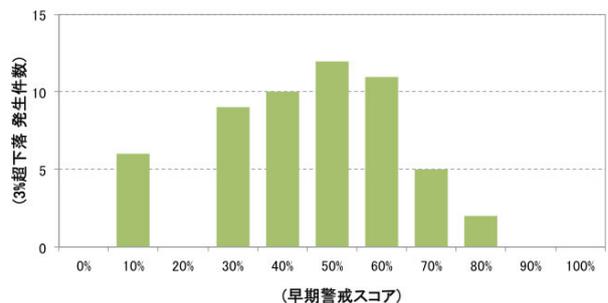


図6 早期警戒スコアとテールリスク顕在化件数 (2005年～2014年)



¹⁰ 本稿では、TOPIX の下落率が3.0%を超える局面を、テールリスク顕在化局面として分析を行った。

3 実証分析

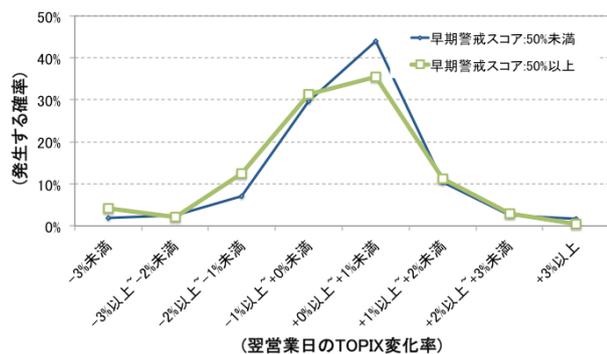
構築した AI 予兆管理システムについて、その予測性能と株式投資における有効性を、2015 年 1 月～2017 年 12 月の市場データ（以下、評価用データ）を用いて検証する。

3.1 予測性能の検証

AI 予兆管理システムの予測性能の検証にあたり、評価用データを早期警戒スコアが 50%未満のグループと 50%以上のグループに分け、翌営業日の TOPIX 日次変化率の比較を行う。

図 7 に、両グループの翌営業日の TOPIX 日次変化率の確率分布図を示す。ここから、早期警戒スコアが 50%以上のグループは、評価用データにおいても翌営業日の TOPIX が下落する確率が相対的に高いことがわかる。この結果から、AI 予兆管理システムが一定の予測性能を有していることを確認した。

図 7 TOPIX 日次変化率の確率分布図 (2015 年～2017 年)



3.2 投資シミュレーション

前節の結果から、早期警戒スコアの水準に応じてヘッジ売りを行うことで、TOPIX の下落リスクを回避し、株式投資のリスクリターン効率を改善できると考えられる。そこで、「早期警戒スコアが 50%未満の場合は TOPIX を保有し、50%以上の場合はヘッジ売り（無リスク資産を保有）を行う」というリスク回避的な投資戦略をとることで、株式投資のリスクリターン効率を改善できるか検証する。

投資シミュレーションを行うにあたり、時点 t の取引（TOPIX と無リスク資産の交換）は、同時点の早期警戒スコアを参照して行うものとし、約定価格は同時点の終値とする。また、取引の際には 5bp (0.05%) の取引コストがかかるものとする。

投資シミュレーション結果を表 3 に示す。投資シミュレーションのシャープレシオは TOPIX を上回り、インフォメーションレシオも 0.5 を上回る水準となった。この結果から、AI 予兆管理システムを利用することにより、株式投資のリスクリターン効率を改善できることを確認した。

表 3 投資シミュレーション結果 (2015 年～2017 年)

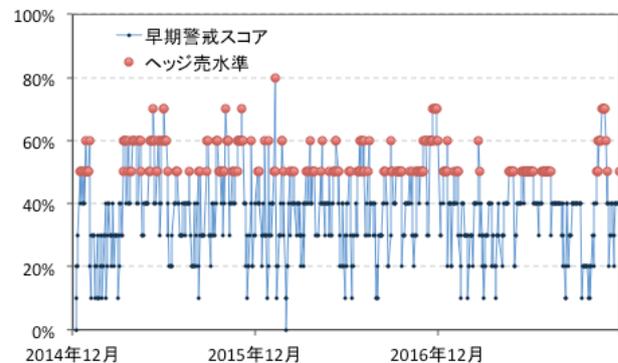
	収益率 (年率)	標準偏差 (年率)	シャープ レシオ	インフォメーション レシオ
投資シミュレーション①	19.27%	12.45%	1.5481	0.7233
TOPIX②	11.86%	15.99%	0.7416	-
差(①-②)	7.42%	-3.54%	0.8065	-

(注) 収益率(年率)は月次の平均収益率に 12 を乗じたもの。標準偏差(年率)は、月次の標準偏差に $\sqrt{12}$ を乗じたもの。

図 8 投資シミュレーションのパフォーマンス (2015 年～2017 年)



図 9 早期警戒スコアの推移 (2015 年～2017 年)



4 おわりに

本稿では、株式投資の予兆管理に AI を用いる手法を提案し、投資戦略に応用することを試みた。提案手法を TOPIX の予兆管理に適用したところ、一定の予測性能を得ることに成功した。また、提案手法を用いた投資戦略において、株式投資のリスクリターン効率を改善する結果が得られたことから、AI 予兆管理システムの株式投資における有効性を確認した。

一方、テールリスク顕在化の兆候については、本稿の提案手法により検知することができなかった。これについては今後、AI トレーダーの改良や早期警戒スコアの算出方法の精緻化等、AI 予兆管理システムの精度向上を図ることにより実現したい。

株式投資におけるリスクリターン効率の改善や効率的な予兆管理スキーム構築等の取組みにおいて、本稿の提案手法が少しでも参考になれば幸いである。

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

参考文献

- [1] 石原龍太, “多層ニューラルネットワークと GA を用いた TOPIX 運用 AI”, 第 19 回人工知能学会 金融情報学研究会 SIG-FIN-019-07, (2017)
- [2] 伊藤敬介, 佐々木洋, “超低金利環境下における金融機関の有価証券運用”, 証券アナリストジャーナル 55(3), (2017)
- [3] 田代大悟, 和泉潔, “高頻度注文情報の符号化と深層学習による短期株価予測”, 第 20 回人工知能学会 金融情報学研究会 SIG-FIN-020-17, (2018)
- [4] 多田智史, “あたらしい人工知能の教科書”, 翔泳社, (2016)
- [5] 砺波元, “資産運用のパフォーマンス測定”, 金融財政事情研究会, (2000)
- [6] 花森利弥, 西村利浩, “システムの異常予兆を検知するリアルタイム監視ソリューション”, 雑誌 FUJITSU 2016-3 月号, (2016)

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

Fluctuation model of JGB yield curve
using machine learning and the interest rate prediction

水門善之^{1,2}

Yoshiyuki Suimon^{1,2}

¹ 野村証券株式会社 金融経済研究所

¹ Nomura Financial and Economic Research Center

² 東京大学大学院 工学系研究科

² Graduate School of Engineering, The University of Tokyo

Abstract: In this research, I have developed a prediction model of long-term interest rate (long-term government bond yield) using machine learning method (SVM, nonlinear SVM, decision tree, RF, logistic regression, LSTM). As a result, it was confirmed that the accuracy of the LSTM-based model is relatively higher in the long-term interest rate prediction than the other models. Furthermore, long-term interest rate is influenced by interest rate fluctuations in the surrounding maturity due to the influence of arbitrage transactions. Therefore, I constructed a fluctuation model of the yield curve incorporating the relationship between long-term interest rate and the other maturity rates in the form of extending the above-mentioned LSTM-based prediction model. As a result, when using the yield curve fluctuation model for predicting long-term interest rate, some improvement was seen in the prediction accuracy of long-term interest rate.

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り、経済の体温計とも呼ばれる。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。そして、長期国債の価格から求まる利回り（長期金利）もそれに伴って変化していく。本研究では、このような長期金利を対象として、各種機械学習手法を用いた先行き予測精度の検証を行った。特に、近年、深層学習を用いた機械学習手法が注目されている点を踏まえ、本研究では時系列分析への有用性が知られる LSTM (Long Short Term Memory) [1]を用いた予測モデルの作成を行い、他の機械学習手法 (SVM, 非線形 SVM, 決定木, RF, ロジスティック回帰, k近傍法) に基づく予測モデルとの、先行き予測精度の比較を行った。結果、LSTM ベースのモデルにおいて、長期金利の相対的な予測精度の高さが確認できた。

更に、長期国債は周辺年限の国債との裁定取引の

影響等から、周辺年限の金利変動の影響を受けやすいという金融市場の特性を踏まえ、本研究では、前述した LSTM ベースの予測モデルを拡張する形で、長期金利と他年限金利の関係（金利の期間構造）を考慮したイールドカーブの変動モデルの構築を行った。結果、金利の期間構造を考慮した予測モデルを用いた場合、長期金利の予測精度に改善の傾向が見られた。このことは、長期国債の価格形成に影響を与え得る国債の年限間の相対価値 (Relative Value) の情報が、長期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言えよう。

長期金利と国債イールドカーブ

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。

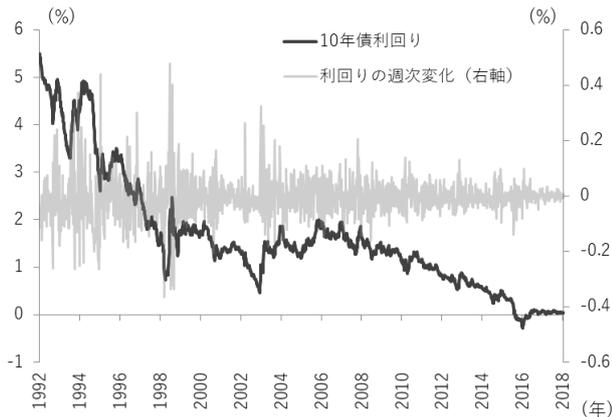


図 1: 日本の長期金利の推移

本研究では、長期金利として日本の 10 年国債の利回りを扱う。長期金利の推移は図表 1 に示した通りである。他にも、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。それら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)。

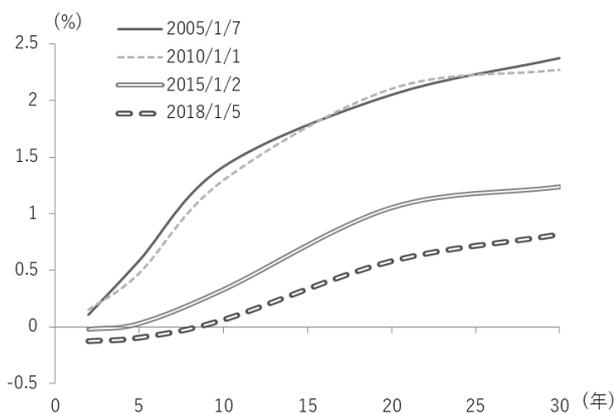


図 2: 日本国債のイールドカーブ

国債は年限によって市場参加者が異なることから、年限によってその変動特性も異なる。例えば、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ことから変動性は乏しい。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変動する。また、長期国債の先物に連動する 7 年付近の金利はヘッジファンド等のアクティブな投資家の影響が表れやすく、当該年限がイールドカーブ全体の動きを主導する場面も見受けられる。

機械学習を用いた長期金利予測

これらを踏まえ、以下では長期金利を対象として、各種機械学習手法を用いた先行き予測の検証を行う。近年、深層学習 (Deep Learning) を用いた様々な金融経済分析が行われており、その応用範囲は多岐に渡っている。中でも、リカレントニューラルネットワーク (RNN) の一種である、LSTM (Long Short Term Memory) [1] は時系列分析での有用性が知られており、株価予測への応用 [2] なども行われている。

本節では、LSTM の長期金利予測での有効性を検証するため、他の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)、非線形 SVM (非線形サポートベクターマシン、Gaussian カーネル使用)、決定木、RF (ランダムフォレスト)、ロジスティック回帰、 k 近傍法に基づく予測モデルとの比較を行った。分析に使用したのは 1992 年 7 月から 2018 年 6 月までの 10 年日本国債利回りの週次変化のデータ [3] である。

具体的には、過去 3 週間の利回りの変化に対して、先行き 1 週間の利回りの変化を教師ラベルとし、モデルの学習を行った (図 3)。SVM、決定木、RF、ロジスティック回帰、 k 近傍法については、教師ラベルを金利の上昇か低下の二値とした。また、LSTM の場合は、先行き 1 週間の金利変化を教師ラベルとし、予測値に基づいて上昇か低下の判別を行った。

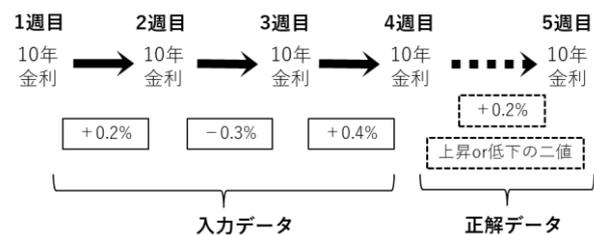


図 3: 学習データ

本研究で用いたプログラミング言語は Python であり、各機械学習手法は scikit-learn 及び、TensorFlow をバックエンドとした Keras を用いて実装した。なお、本研究で実装した LSTM モデルの構造は次節で詳解する。

本研究では、対象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割のテストデータを対象として学習済みモデルの予測精度の検証を行った。更に、同様の方法で4種類のテストデータを作成し、それらを用いてモデルの予測精度の検証を行った。各種モデル別の長期金利の上昇・低下の方向性予測の正答率は図7に掲載した通りである(図中の「LSTM(期間構造導入)」は次節での提案手法)。これによると、他の手法に基づく予測モデルに比べ、LSTMベースの予測モデルにおいて、長期金利予測の相対的な精度の高さが確認できる。

イールドカーブの変動モデルの構築

前節までは長期金利の単一時系列の変動情報に基づいて先行き予測を行ってきた。しかし実際の長期金利は、国債の年限間の相対価値(Relative Value)に基づいて変化する需要と供給のバランスや、周辺年限の国債との金利差に着目した裁定取引の存在等、様々な投資家行動の影響を受ける。この点を踏まえ、本研究では、前述したLSTMベースの予測モデルを拡張する形で、長期金利と他年限金利の関係(金利の期間構造)を考慮したイールドカーブの変動モデルの構築を行った。

LSTMとはリカレント(再帰)な特性を持つニューラルネットワークであり、入力層と出力層の間にある隠れ層が、再帰的なネットワークとして結合されているものである。LSTMが通常のリカレントニューラルネットワーク(RNN)と異なる点は、隠れ層における各ユニットが、LSTMブロックと呼ばれる構造をしている点である。なお、本研究で用いたモデルでは隠れ層のユニット数は100としている。

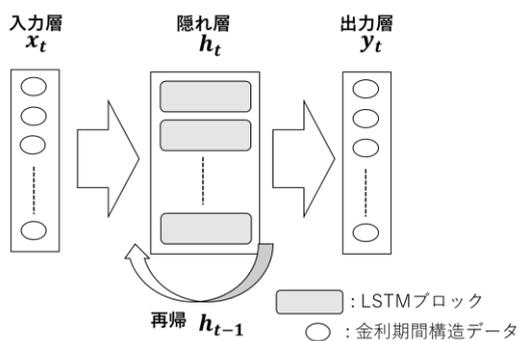


図4: LSTMモデルの説明

分析に使用したデータは前節同様、1992年7月から2018年6月までの日本国債利回りの週次データ[3]である。前節での長期金利の予測モデルでは、学習に用いた入力データ x_t は10年利回りの変化のみであったが、ここでは、図5に示す通り、5年、10年、20年の金利変化及び、それぞれの年限の相対的

な金利差という5次元のベクトルを入力データ x_t として設定する。そして、これらの過去3週間の変化に対して、先行き1週間の変化の情報を教師ラベルとして、モデルの学習を行う。

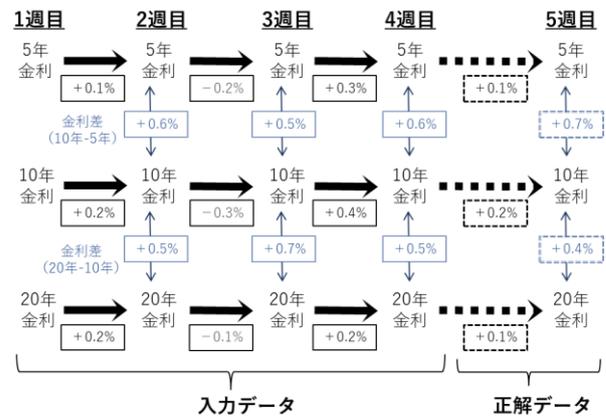


図5: 拡張モデルの学習データ

このようなイールドカーブの形状変化を表現するため、本モデルの入力層 x_t と出力層 y_t のデータとして、以下のベクトルを設定する。

$$x_t = \begin{pmatrix} r_t^{20} - r_{t-1}^{20} \\ r_t^{20} - r_t^{10} \\ r_t^{10} - r_{t-1}^{10} \\ r_t^{10} - r_t^5 \\ r_t^5 - r_{t-1}^5 \end{pmatrix}, y_t = \begin{pmatrix} r_{t+1}^{20} - r_t^{20} \\ r_{t+1}^{20} - r_{t+1}^{10} \\ r_{t+1}^{10} - r_t^{10} \\ r_{t+1}^{10} - r_{t+1}^5 \\ r_{t+1}^5 - r_t^5 \end{pmatrix}$$

入力層から隠れ層に入ったデータ x_t はLSTMブロック内での再帰構造により、過去の入力データの影響を受ける。本モデルでは過去3週間の週次変化を表す以下のベクトルを入力層のデータとして学習に用いる。

$$x_t, x_{t-1}, x_{t-2}$$

本モデルで設定した隠れ層におけるLSTMブロックの構造は以下の通りである。

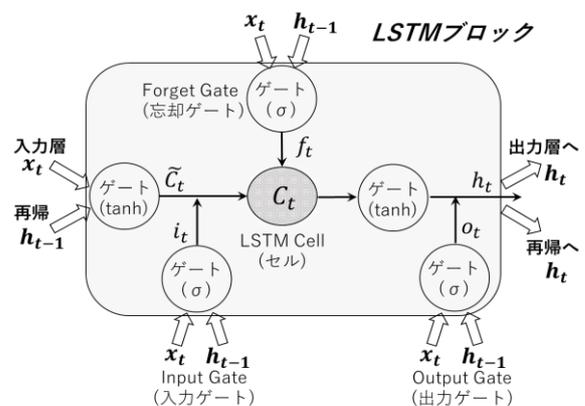


図6: LSTMブロックの説明

入力層からのデータ x_t と再帰データ h_{t-1} は、LSTM ブロックに入った後、ゲート（活性化関数）を通じて以下のように \tilde{C}_t として変換される。

$$\tilde{C}_t = \tanh(W_c \cdot [x_t, h_{t-1}] + b_c)$$

LSTM ブロック内の \tilde{C}_t は、更に入力ゲートと忘却ゲートからの出力値 i_t, f_t によって更新され C_t となる。ここでの活性化関数 σ はシグモイド関数とする。

$$i_t = \sigma(W_i \cdot [x_t, h_{t-1}] + b_i)$$

$$f_t = \sigma(W_f \cdot [x_t, h_{t-1}] + b_f)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

更に C_t は、 \tanh で設定されるゲートを通過した後、出力ゲートからの出力値 o_t によって出力がコントロールされ、最終的に隠れ層から h_t が出力される。

$$o_t = \sigma(W_o \cdot [x_t, h_{t-1}] + b_o)$$

$$h_t = o_t * \tanh(C_t)$$

そして、隠れ層の出力値 h_t は、下式の通り線形活性化関数を介して出力層 y_t に繋がる。

$$y_t = Vh_t + C$$

本研究では、このような LSTM ベースのモデルを用いて、長期金利と他年限金利の関係（金利の期間構造）を考慮したイールドカーブの変動モデルの作成を行った。そして、作成したモデルを用いて予測した 1 週間先のイールドカーブの変化に基づいて、長期金利の上昇、低下の方向性の予測精度の検証を行った。ここでは、前節での他手法との比較のために、学習に用いたデータ期間及び、検証に使用したテストデータの期間は、前節で用いたもの同一の期間とした。検証結果は図 7 の「LSTM (期間構造導入)」に示した通りである。本検証結果に基づくと、長期金利の予測精度に改善の傾向が見られた。

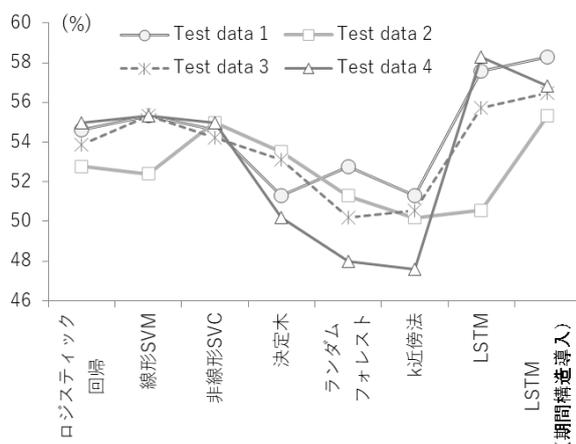


図 7: 長期金利の方向性予測の正答率

ただし、今回確認された LSTM モデルの優位性はあくまで時系列特性に依存するものであり、テストデータによっては、SVM 等と正答率が同程度のケースも見受けられる。本分析で対象とした長期金利の変動は、図 1 に示した通り、時期によってその大きさが変化しており、例えばサンプル期間中においては、1990 年代に金利変動の大きさが目立っている。一方、足元では日本銀行による「長短金利操作付き量的・質的金融緩和」[4]の下、長期金利（10 年国債の利回り）が概ねゼロ%程度で推移するような長期国債の買入れが行われており、長期金利の変動性は低下している。このように、マクロ経済環境や金融政策運営等を背景に、金利の時系列特性も変化していく点には注意が必要である。

まとめと解釈

本研究では、LSTM ベースの機械学習手法を用いてイールドカーブの変動モデルの構築を行った。特に、年限間の相対価値 (Relative Value) に基づいて国債の需要が変動する市場特性や、周辺年限の国債との金利差に着目した裁定取引の存在等、イールドカーブの変動が、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点に着目し、金利の期間構造を考慮したイールドカーブの変動モデルの構築を行った。結果、金利の期間構造を考慮した予測モデルを用いた場合、長期金利の単一時系列を用いた予測モデルに比べて、予測精度に改善の傾向が見られた。このことは、長期国債の市場価格の形成に影響を与え得る国債の年限間の相対価値の情報が、長期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言えよう。

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。

参考文献

- [1] Sepp Hochreiter, Jürgen Schmidhuber: Long Short-Term Memory, Neural Computation, Vol.9, No.8, pp.1735–1780, (1997)
- [2] 松井藤五郎, 汐月智也: LSTM を用いた株価変動予測, 人工知能学会第 31 回全国大会論文集, (2017)
- [3] 財務省: 国債金利情報
https://www.mof.go.jp/jgbs/reference/interest_rate/
- [4] 日本銀行: 金融緩和強化のための新しい枠組み「長短金利操作付き量的・質的金融緩和」, (2016)

高頻度注文情報の時系列性考慮による短期市場動向予測

Short-time market trend prediction by considering time series of high frequency order

前田 巖^{1*} 松島 裕康¹ 坂地 泰紀¹ 和泉 潔¹
ディグロー デビット² 富岡 博和² 加藤 惇雄³
Iwao Maeda¹ Hiroyasu Matsushima¹ Hiroki Sakaji¹ Kiyoshi Izumi¹
David deGraw² Hirokazu Tomioka² Atsuo Kato³

¹ 東京大学

¹ The University of Tokyo

² 大和証券株式会社

² Daiwa Securities Co. Ltd.

³ 株式会社大和総研

³ Daiwa Institute of Research Ltd.

Abstract: 高頻度取引 (HFT) により得られる高頻度注文情報を用いた短期の市場動向予測に注文が集まっている。高頻度注文情報は同時多発的な注文の系列であるため、隣接するデータの順序情報にノイズが大きく、より広いデータ範囲におけるロバストなパターン認識が必要である。本研究では注文情報のパラメータ化および畳み込みニューラルネットワーク (CNN) の活用を通し、この問題の解決を図った。注文情報に対する適切な情報抽出を行い、CNN を用いて予測モデルを構築することで、注文パターンに対しロバストな予測が可能になる手法を提案する。実験の結果、FLEX_FULL 注文データに対する解析で、本手法が高い精度で未来の株価動向を予測できることを確認した。

1 序論

金融市場の電子化・高速化に伴い、アルゴリズム取引や高頻度取引 (HFT) といった機械的な取引が台頭している。同時に、機械的な取引により生成される注文情報、取引情報も高頻度化、膨大化が進行し、金融市場の動向予測、および市場のメカニズム解明に対し有効な利用が期待されている。特に、近年発展を続ける機械学習・深層学習技術の適用により、高頻度注文情報からデータ背後の関係性を学習し、特徴抽出や予測を行う研究が行われている [1]。

高頻度注文情報は非常に高頻度で獲得できる注文情報であり、ミリ秒単位、注文単位の非常に短期間における市場動向の予測に活用できると考えられる [2]。高頻度注文情報を用いた短期の市場動向予測においては、高頻度注文情報の時系列性を適切に考慮し、特徴抽出を行うことが必要である。ミリ秒単位の同時多発的な注文の系列である高頻度注文情報では、隣接する注文の順序情報にノイズが大きい。単純に注文系列のパター

ンを学習しただけでは、市場の動向に有用な情報を抽出できるとは考えづらい。より大きな時間領域の注文パターンをロバストに学習することにより、有用な予測が可能になると考えられる。

本研究ではロバストなパターン認識を可能にするため、注文情報のパラメータ化および畳み込みニューラルネットワーク (CNN) の活用を通しこの問題の解決を図った。

2 データ

FLEX_FULL ヒストリカルデータを用いた。各銘柄について、2013年7月1日から100営業日分を使用した。予測対象は、予測時点から20注文後時点での仲値の上昇・下降とし、予測時点の仲値から1 tick 分をしきい値として、上昇、下降、変化なしの3クラス分類で解析を行った。入力には、予測時点から過去100件の注文情報を用いた。

*連絡先：東京大学大学院工学系研究科システム創成学専攻和泉研究室

〒113-8654 東京都文京区本郷 7-3-1
E-mail: d2018imaeda@socsim.org

3 手法

3.1 注文情報のパラメータ化

注文情報を入力データとして深層学習モデルを構築するため、注文情報のパラメータ化を行った。本研究では、注文の種類（指値注文，成行注文，キャンセル注文），売り買い，価格，注文量，および注文時の仲値を考慮し，以下のように各注文について3次元の数値データ $(x_{\text{price}}, x_{\text{amount}}, x_{\text{midprice}})$ への変換を行うことで，注文からの特徴抽出を行った。3つの変数はそれぞれ，注文価格，注文量，注文時の仲値を表している。

$$x_{\text{price}} = P - MP \quad (1)$$

$$x_{\text{amount}} = \log(A) \quad (2)$$

$$x_{\text{midprice}} = MP - MP_- \quad (3)$$

ここで，P，MP，A，MP₋ はそれぞれ，注文価格，注文時の仲値，注文量，直前注文の仲値を表す。注文価格，および仲値について差分を取ることで，データの正規化を行っている。また，買い注文では $x_{\text{price}} > 0$ ，売り注文では $x_{\text{price}} < 0$ ，指値注文および成行注文では $x_{\text{amount}} > 0$ キャンセル注文では $x_{\text{amount}} < 0$ となり，注文の種類が区別可能となる。

以上のように変換した3次元データを過去100注文分結合し， 100×3 次元の特徴量を各時点に対する説明変数とした。

3.2 深層学習モデル

表1のようなCNNモデルを作成し，学習を行った。Dropout層の25%はdropoutを行う割合を表している。1層目の畳み込み層では注文方向および注文パラメータ方向に畳み込みを行い，2層目以降では注文方向に畳み込みを行っている。活性化関数にはReLU関数を用いた。学習時には，サンプル数の比に応じクラスごとに重みを設定し損失関数の計算を行っている。

4 結果

使用した100営業日のデータのうち，前半50日をモデル構築用データ，後半50日をモデル検証用データとして解析を行った。

企業コード3407に対する結果を以下に示す。提案手法の精度評価指標を表2に示す。Trainingがモデル構築用データに対する精度指標を，Testがモデル検証用データに対する精度指標を表している。比較として，ロジスティック回帰で予測モデルを作成した場合の結果を表3に示す。各データに対するAccuracyおよびF1

表 1: 提案手法のネットワーク構成

type	patch size	stride	output size
convolution	3 × 3	1	98 × 1 × 64
convolution	3 × 1	1	98 × 1 × 64
max pool	3 × 1	2	49 × 1 × 64
dropout(25%)			49 × 1 × 64
convolution	3 × 1	1	49 × 1 × 64
convolution	3 × 1	1	49 × 1 × 64
max pool	3 × 1	2	24 × 1 × 64
dropout(25%)			24 × 1 × 64
convolution	3 × 1	1	24 × 1 × 64
convolution	3 × 1	1	24 × 1 × 64
max pool	3 × 1	2	12 × 1 × 64
dropout(25%)			12 × 1 × 64
linear			3
softmax			3

scoreは，上昇・下降・変化なし3クラスそれぞれに対するスコアの，各クラスのデータ数を用いた重み付き平均で計算されている。AccuracyおよびF1 scoreの値より，高い精度で短期の仲値動向を予測できていることがわかる。

提案手法の優れている点として，予測の正解率 (precision) が高く，実際の動向と逆方向の予測を出すことが非常に少ないことが挙げられる。表4および表5に，提案手法，ロジスティック回帰のモデル検証用データに対する混同行列，および予測に対する割合を示す。

予測ラベルおよび実際のラベルは，Downが下降，Stayが変化なし，Upが上昇を表している。表4より提案手法ではDownと予想した場合に実際に実際はUpおよびDownである割合がそれぞれ23.8%，1.1%となっており，実際と逆方向の変動を予測する可能性が，実際の変動を正しく予測する可能性に比べ非常に低いことがわかる。対してロジスティック回帰では，同様の割合がそれぞれ10.6%，1.5%となっており，提案手法に比べ正解率および実際と逆方向の予測を行う確率が高くなっている。予測の正解率および実際と逆方向の予測を行う確率は特に金融商品の取引において重要であり，その点で提案指標がより適しているといえる。

表 2: 提案手法の精度指標

	Accuracy	F1 Score
Training	0.880	0.866
Test	0.875	0.855

表 3: ロジスティック回帰の精度指標

	Accuracy	F1 Score
Training	0.356	0.488
Test	0.353	0.497

表 4: 提案手法のモデル検証用データに対する混同行列および予測に対する割合

	Predicted:		
	Down	Stay	Up
Actual:			
Down	7823(23.8%)	51345(4.7%)	219(1.3%)
Stay	24676(75.1%)	976845(90.3%)	11452(66.8%)
Up	368(1.1%)	53894(5.0%)	5464(31.9%)

表 5: ロジスティック回帰のモデル検証用データに対する混同行列および予測に対する割合

	Predicted:		
	Down	Stay	Up
Actual:			
Down	14110(10.6%)	42656(5.1%)	2621(1.7%)
Stay	116261(87.8%)	759223(90.2%)	137489(86.9%)
Up	2003(1.5%)	39561(4.7%)	18162(11.5%)

5 まとめ

高頻度注文情報を用いた短期の株価動向予測を行った。注文情報のパラメータ化および CNN の活用により、高頻度注文情報が持つ系列性を適切にモデリングでき、高い精度で価格動向を予測することができた。

6 免責事項

本稿は、著者の個人見解を表すものであり、大和証券株式会社および株式会社大和総研の公式見解を表すものではありません。

参考文献

- [1] E. Chong, C. Han, and F. C. Park,: Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies, *Expert Syst. Appl.*, Vol. 83, pp. 187–205 (2017)
- [2] 田代大悟: 平成 29 年度 修士論文 (2018)

カバー先銀行の集合知による外国為替ベストレート予測

Prediction of Foreign Exchange Best Rates by Collective Knowledge of Counter Party Banks

鈴木 丈裕^{1*} 矢野 和洞¹ 鈴木 智也^{1,2}
Takehiro SUZUKI¹ Kazuto YANO¹ Tomoya SUZUKI^{1,2}

¹ 茨城大学大学院理工学研究科

¹ Graduate School of Science and Engineering, Ibaraki University

² コラボウィズ株式会社

² CollabWiz, Inc.

Abstract: In foreign-exchange (FX) dealing, FX brokers basically cancel out the orders from their customers to prevent the price fluctuation risk by cover transactions with global megabanks called Counter Party (CP). Each CP has huge amount of money to play a role of market reader, and might have proprietary know-how to foresee future price movements. From this viewpoint, we try to extract their knowledge by a machine learning approach, and therefore we apply the stacking method that aggregates some predictors to extract the ensemble knowledge. If CP's price quotations are decided by foreseeing future price possibilities, their quotations can be considered as predictors. From this concept, we apply the stacking method to their quotations and obtain the ensemble knowledge from them. Through some simulations using real price data, we could confirm that the given ensemble knowledge improves the prediction accuracy of FX price movements compared to the machine learning using a single CP's price quotation.

1 はじめに

外国為替証拠金取引 (Foreign Exchange: FX) において、店頭外国為替証拠金取引取扱業者 (以下、FX 業者) は顧客と各国の通貨間の売買を行う際に、価格変動に伴う損失のリスクを減らすカバー取引を銀行と行う。これらのカバー先銀行をカウンターパーティ (Counter Party: CP) と呼び、FX 業者は CP から送信される各通貨間の Bid(売値) と Ask(買値) の為替レート建値 (為替相場で銀行が公表する取引価格) に基づいて顧客に提示する自社のレートを生成している。このとき CP から送信される為替レート建値を CP レート、顧客に提示する自社のレートをハウスレートと呼ぶ。ここで CP からレートを受信する構造上、ハウスレート生成に低遅延が発生する。このような受信による遅延やシステム障害による遅延により他の FX 業者と大きく異なるレートを提示してしまった場合、業者間裁定取引者 (各業者間のハウスレートの価格差を利用して収益を上げる顧客) のターゲットにされる怖れがある。ここで FX 業者が極短時間後の CP レートを予測し、ハウスレー

トを通常よりも早く更新することでこの遅延を低減できれば、収益の悪化を抑制できる。さらにレート更新の早さは、市況情報に対する正確性から顧客を多く獲得でき、他の FX 業者との競争において有利になるメリットもある。これらの観点から、CP レートの将来価格を予測することは FX 業者の収益獲得に繋がる可能性がある。

ここで将来価格の予測に関して、カバー先である CP に着眼する。各 CP 同士は収益獲得競争のため相場をある程度先読みして CP レートを生成しており、CP ごとに様々なノウハウを有している可能性がある。そこで本研究では FX 業者の立場になり [1]、各 CP の建値情報 [2] をアンサンブル学習の一種であるスタッキング [3] の概念を用いて集合知 [4-7] を抽出する。この集合知を用いることで効率的市場仮説 [8] によってランダムウォークのように予測不可能とされる為替変動に対して、どの程度予測力を高められるか検証する。

2 スタッキングによる集合知の獲得

まず一般的なスタッキングを図 1 に示す。共通のオリジナルデータを用いて複数の異なる予測モデルを学

*連絡先: 茨城大学大学院理工学研究科知能システム工学専攻
〒316-8511 茨城県日立市中成沢町 4-12-1
E-mail: 17nm9261@vc.ibaraki.ac.jp

習し、それらが出力した予測値に対して新たに別の予測モデルでメタ学習することで、最終的な予測値を得る [9]。これに対して本研究では図2に示すように、共通のオリジナルデータを全世界の市況情報と見立てて、ノウハウを有する各CPを予測器と考える。これらをニューラルネットワークでメタ学習することで、各CPのノウハウを統合した集合知を獲得する。この集合知が最終的な予測値として機能するのか確認するため、CP毎の建値情報のみを機械学習する予測モデル（個別法）とスタッキングの概念を応用した提案法を比較する。

集合知の効果を示す一例として多様性予測定理 [10] を紹介する。各予測モデルから得られる予測値の分散（多様性）が大きいほど集合知の予測誤差が縮小することが知られている。全 N 個の予測モデルにおいて、第 i 番目のモデルによる個別の予測値を \hat{y}_i 、これらを統合した集合知による予測値を $E[\hat{y}] = \frac{1}{N} \sum_{i=1}^N \hat{y}_i$ 、真値を y とすると、以下の等式が成立する。

$$(y - E[\hat{y}])^2 = \frac{1}{N} \sum_{i=1}^N (y - \hat{y}_i)^2 - \frac{1}{N} \sum_{i=1}^N (\hat{y}_i - E[\hat{y}])^2 \quad (1)$$

ここで左辺は集合知の予測誤差、右辺第1項は各予測モデルの平均予測誤差、右辺第2項は予測モデルの分散値に相当する。つまり多様なCPの建値情報を統合することで互いの不正確な予測を打ち消し合うことで集合知を獲得し、右辺第2項のような誤差低減効果を期待できる。

補足として、説明変数に用いるCPおよび通貨ペアを増やすほど機械学習に伴う入力次元数が増加するため、Deep Neural Network [11] が効果的であろう。しかし本稿の設定（次章）では比較的低次元であるため、通常の3層ニューラルネットワークを用いる。

3 問題設定

本研究では、2017年9月4日から9月30日までのFX業者に送信された計12社のCPレートから、「ドル円」、「ユーロ円」、「ユーロドル」の3つの通貨ペアを使用する。なお流動性が高く、マーケットインパクトが相対的に小さい（=市場参加者が多い）当日午前8時から翌日午前5時までを1日分の市場データとして扱う。そして、ある1日を学習期間、次の1日をテスト期間とする。例えば、「9月4日午前8時から9月5日午前5時のデータで学習→9月5日午前8時から9月6日午前5時のデータでテスト」のように行った。外国為替取引は土日が休みのため、1週間に行うシミュレーションは4期間となり、4週間分のデータを用いたため合計16期間となる。また、送信されるレートはBid(売値)とAsk(買値)の2値が存在するため、16期間×2値=計32パターンのシミュレーションを実施す

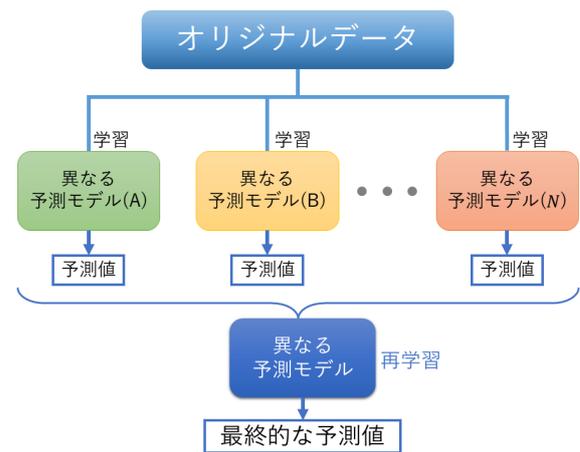


図1: 一般的なスタッキングの例

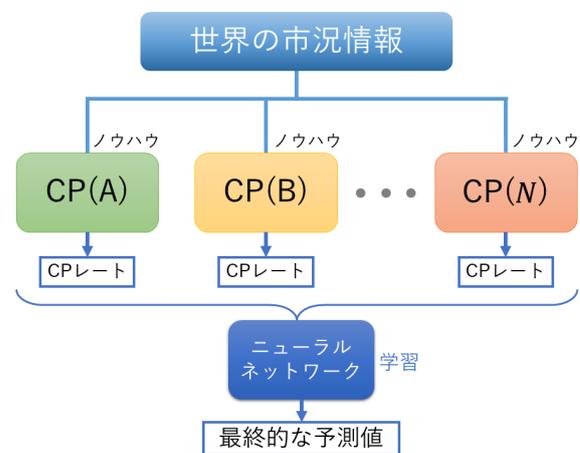


図2: CPレートをを用いたスタッキング（提案法）

る。予測対象の目的変数は時刻 $t+1$ (100[ms] 後) のドル円のベストレート (全CPにおける最も高いBid(売値)および最も低いAsk(買値)) とする。ドル円は通貨ペアの中でも流動性が高く、取引回数も多い利点がある。予測に用いる説明変数は、過去のドル円レートおよび関連するユーロ円およびユーロドルの3種類を用い、時間履歴を学習するように時刻を t (現在時刻)、 $t-1$ (100[ms] 過去)、 $t-2$ (200[ms] 過去) のようにラグを取ってニューラルネットワークに入力した。また、各通貨ペアにおいて為替レート $x(t)$ の価格帯が異なるため、収益率 $r(t)$ に変換した。

$$r(t) = \frac{x(t) - x(t-1)}{x(t-1)} \quad (2)$$

例として図3に、変換前と変換後の例を示す。ニューラルネットワークの構成として、出力層のニューロン数は1つであり、中間層のニューロン数は入力層の1.1

倍 (バイアス項含む) に設定した. 入力層のニューロン数については,

- 個別法の場合 :
CP 数 (= 1) × 通貨ペア数 (= 3)
× 時間履歴数 (= 3) + バイアス項 (= 1) = 10 個
- 提案法の場合 :
CP 数 (= 12) × 通貨ペア数 (= 3)
× 時間履歴数 (= 3) + バイアス項 (= 1) = 109 個

となる. なお学習係数は全て 0.001 に設定した.

4 予測シミュレーション

4.1 正答率と F 値による評価

ニューラルネットワークの出力値である収益率 $\hat{r}(t+1)$ が正ならば次時刻の為替レート $\hat{x}(t+1)$ は上昇, 負ならば下落, 0 ならば不変とし, レート変動方向に関する正答率 A を評価する. しかし予測値 $\hat{r}(t+1)$ が丁度 0 になることは無いため, 学習対象の目的変数について標準偏差 σ を求め, この $\pm\sigma$ の範囲内の $\hat{r}(t+1)$ を不変とみなした. 正答率 A の算出には,

- 上昇と予測し, 実際には上昇した回数 : U_{win}
- 上昇と予測したが, 反して下落した回数 : U_{lose}
- 下落と予測し, 実際には下落した回数 : D_{win}
- 下落と予測したが, 反して上昇した回数 : D_{lose}

を用い, 次式によって計算する.

$$A = \frac{U_{win} + D_{win}}{U_{win} + U_{lose} + D_{win} + D_{lose}} \quad (3)$$

このように不変と予測した場合を除くことで, 元々のデータに不変の割合が多く正答率が 100[%] に近くなることを防ぐ. さらに, 上昇または下落に関する二択問題となるため, 50[%] を基準に有用性を評価できる. さらに, 正答率を算出する際にデータ数の偏りを考慮して, F 値 (F-measure) による評価も行う. これは以下の適合率 $Precision$ と再現率 $Recall$ から算出される.

- Bid(売値) レートを予測対象にする場合

$$Precision = \frac{U_{win}}{U_{win} + U_{lose}} \quad (4)$$

$$Recall = \frac{U_{win}}{U_{win} + D_{lose}} \quad (5)$$

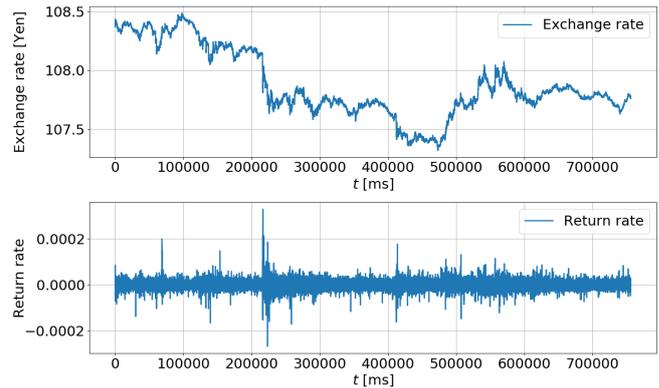


図 3: (上図) 実際の為替レート $x(t)$, (下図) 変換後の収益率 $r(t)$

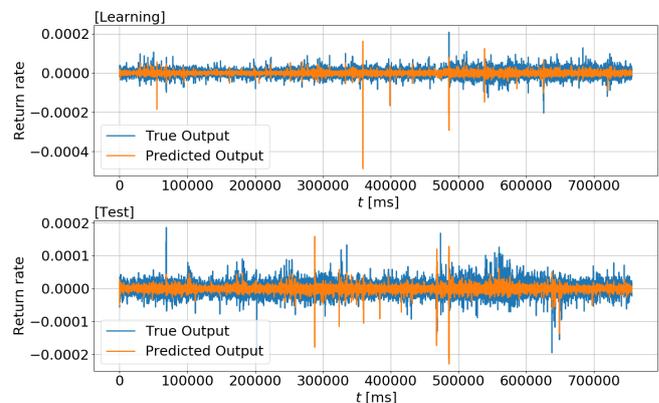


図 4: (上図) 学習時 (Learning) の真値 $r(t)$ と予測値 $\hat{r}(t)$, (下図) テスト時 (Test) の真値 $r(t)$ と予測値 $\hat{r}(t)$

- Ask(買値) レートを予測対象にする場合

$$Precision = \frac{D_{win}}{D_{win} + D_{lose}} \quad (6)$$

$$Recall = \frac{D_{win}}{D_{win} + U_{lose}} \quad (7)$$

これらの F 値は以下のように算出される.

$$F = \frac{2Precision \times Recall}{Precision + Recall} \quad (8)$$

4.2 結果および考察

図 4 はある学習期間・テスト期間の収益率 (Return rate) の真値と予測値を示している. True Output は真値, Predicted Output は予測値である. このような結果に基づいて, 提案法と個別法を比較した正答率の結果を表 1, F 値の結果を表 2 に示す. 例として「9

月5日」が示すのは、9月5日午前8時から9月6日午前5時である。各表において、個別法による結果を「CP(A),CP(B),...,CP(L)」の各項目に示す。また、個別法による結果の平均値を $Mean\{CP\}$ と表す。表中の各項目において、Bid(売値)とAsk(買値)をそれぞれ予測した結果を同時に示している。これらより、提案法は必ずしも常に1位ではないが、安定して上位を保っている。対して個別法は良くなる場合も悪くなる場合もあり、順位が安定しない。この結果から、集合知の効果が発揮されていると考えられる。また、9月15日のように提案法の値が著しく低い場合も確認できる。これは学習期とテスト期で相場が大きく異なり、学習した市場の動きがテスト期に適用していないためと考えられる。(2017年9月15日は北朝鮮が弾道ミサイルを発射し、北海道上空を通過した後太平洋上に落下し、飛行距離が過去最長の約3700kmに達したとされたニュースがあり、これが為替変動に影響を及ぼした可能性がある。) またF値において個別法の結果に大きな差が確認できるため、 $+\sigma$ を上回り上昇と判別されたデータ数と、 $-\sigma$ を下回り下落と判別されたデータ数に偏りがあると考えられる。

さらに図5および図6に示すように、正答率とF値について、提案法と個別法(平均値)の比較を行った。図5は正答率、図6はF値を示す。それぞれBid(売値)とAsk(買値)の予測結果を示している。これらより、正答率は「9/14のAsk」と「9/15」の2期間を除く全ての期間、F値は全ての期間において、提案法が個別法(平均値)を上回る結果となった。これらは各CPによって異なる将来価格の見通しを集団学習によって統合することで、より先見力のある集合知を獲得できたことを示しており、この結果からも集合知の効果が発揮されていると考えられる。また、もし市場がランダムウォークならば正答率は上昇か下落の二択問題により50[%]になると考えられるが、提案法ではほぼ全ての期間で70[%]から80[%]を超える値を示しており、個別法(平均値)においてもほとんどの期間で50[%]を超えている。したがって各CPは市場を予測するノウハウを持っており、さらにスタッキングによってより優れた集合知を獲得できたと考えられる。

5 まとめ

本研究では、外国為替取引を仲介するFX業者の立場になり、各CPから配信される建値を各予測器からの出力値とみなし、これらをスタッキングによって集団学習する価格予測モデルを提案した。実際の建値データを用いた予測シミュレーションを通じて、個別のCP毎で予測モデルを構築するよりもスタッキングによって全CPを統合することで予測精度を向上できることを確認した。

6 今後の課題

自発的な収益獲得のため、本提案手法による価格予測を自己売買の判断材料に利用できる可能性がある。これについて投資シミュレーションを通じて検討する。また本稿においては100[ms]先を予測対象としているが、今後は200[ms]先や300[ms]先のように予測期間を延長しつつ、予測力を保持できるか検証する。

本研究の一部は、文科省科研費基盤研究(C)(No.16K00320)の助成により行われました。

参考文献

- [1] 本研究は某店頭外国為替証拠金取引取扱業者との共同研究である。
- [2] 某店頭外国為替証拠金取引取扱業者から入手した。
- [3] Trevor Hastie, Robert Tibshirani and Jerome Friedman, The Elements of Statistical Learning, Springer, 2008.
- [4] Scott E. Page, The Difference: How the Power of Diversity Creates Better Groups, Firms, Schools, and Societies, Princeton University Press, 2008.
- [5] James Surowiecki, The Wisdom of Crowds, Anchor, 2005.
- [6] Tomoya Suzuki and Yuushi Ohkura, "Financial Technical Indicator Based on Chaotic Bagging Predictors for Adaptive Stock Selection in Japanese and American Markets," Physica A, vol.442, pp.50-66, 2016.
- [7] Tomoya Suzuki, "Consensus Ratio and Two-steps Selection to Detect Profitable Stocks," International Federation of Technical Analysts (IFTA) Journal, vol.18, pp.4-14, 2018.
- [8] Eugene F. Fama, "Efficient Capital Markets: A Review of Theory and Empirical Work," Journal of Finance, vol.25, no.2, pp.383-417, 1970.
- [9] Zhi-Hua Zhou, Ensemble Methods Foundations and Algorithms, Taylor & Francis Group, 2012.
- [10] 西垣通, 集合知とは何か, 中公新書, 2013.
- [11] Tomoya Onizawa, Takehiro Suzuki, Tomoya Suzuki, "Predictability of Financial Market Indexes by Deep Neural Network," Proceedings of 2017 International Symposium on Nonlinear Theory and its Applications, pp.166-169, 2017.

表 1: 各テスト期間における正答率 [%] : Bid(左)/Ask(右). 各列において正答率が高い 3 位までを太字で示す.

テスト期間	9月5日	9月6日	9月7日	9月8日	9月12日	9月13日	9月14日	9月15日
CP(A)	77.77 /55.00	59.24/62.27	67.31/65.06	66.23/67.39	68.80/62.70	67.31/ 72.73	61.68/50.79	73.38 / 74.41
CP(B)	78.83 /63.84	72.91/70.32	61.46/51.37	64.93/74.03	44.35/62.45	71.67 /68.55	0.00/0.00	0.00/0.00
CP(C)	36.70/49.28	68.19/51.34	62.48/64.25	68.50/63.80	56.55/51.71	70.88 /56.79	59.17/44.48	70.38/49.59
CP(D)	65.85/35.47	63.07/68.42	72.86 /70.60	72.83 /66.26	74.38 /72.85	68.58/71.29	69.46 / 75.07	62.47 /50.60
CP(E)	76.51/ 71.00	69.34/ 72.14	61.36/ 72.16	68.93/ 74.53	74.21 / 78.77	63.75/70.93	62.44/37.32	79.54 /61.03
CP(F)	71.43/33.33	61.89/71.44	66.28/54.39	59.04/73.76	55.11/66.75	46.81/72.36	57.96/56.70	71.53/50.75
CP(G)	74.98/65.90	75.98 / 77.03	68.23/67.88	71.32/ 79.89	74.09/72.78	41.88/ 75.81	65.60/68.56	71.94/68.39
CP(H)	60.71/64.67	68.94/69.99	69.13/60.10	69.77/58.95	66.48/65.83	59.18/59.42	60.37/51.05	75.74 /65.37
CP(I)	56.41/62.82	52.06/57.54	56.08/55.32	54.17/57.14	53.41/66.91	64.47/51.92	61.88/53.87	63.55/ 72.33
CP(J)	68.63/ 69.29	75.48/70.38	68.96/62.52	52.28/73.60	67.16/ 74.89	68.97/56.94	68.98 / 70.21	70.94/63.66
CP(K)	29.82/53.93	75.90 /70.05	74.98 /65.50	80.15 /65.65	72.98/67.92	67.98/71.29	66.37 / 69.70	69.53 / 84.29
CP(L)	57.14/48.24	63.36/67.55	56.06/ 71.14	70.71/60.52	62.68/61.21	48.11/65.48	47.14/44.21	68.45/59.80
Mean{CP}	62.90/56.06	67.20/67.37	65.43/63.36	66.57/67.96	64.18/67.06	61.63/66.13	56.75/51.83	64.79/58.35
提案法	80.91 / 77.78	78.67 / 77.29	76.96 / 75.80	79.24 / 80.40	76.09 / 78.03	75.85 / 77.68	64.29/49.13	48.00/56.67

テスト期間	9月19日	9月20日	9月21日	9月22日	9月26日	9月27日	9月28日	9月29日
CP(A)	69.86/71.41	60.34/58.35	70.32/66.02	70.24/ 77.45	72.50/70.61	71.84/57.80	62.67/70.97	71.86/59.94
CP(B)	66.68/68.34	68.03 / 69.32	75.03 /71.86	78.95/69.24	66.14/67.20	72.85/68.83	68.99/68.04	72.72/71.87
CP(C)	63.02/47.49	52.53/62.97	65.25/57.79	59.32/66.67	44.03/49.27	65.16/62.30	57.11/53.14	51.79/57.34
CP(D)	55.82/71.67	57.96/68.48	45.45/76.82	81.97 /69.77	67.34/56.02	73.50 / 75.05	71.34/ 73.60	80.00 / 79.45
CP(E)	72.07 /63.38	42.42/ 69.80	51.35/60.00	81.66 /72.14	75.11 /69.85	80.17 /69.49	79.63 / 77.30	74.03/ 78.62
CP(F)	62.36/ 77.11	58.35/65.39	67.98/70.62	56.93/74.70	67.38/73.05	56.71/69.17	66.86/67.94	64.54/71.94
CP(G)	71.76/68.49	67.25 /69.00	63.30/ 78.52	80.68 /74.34	68.22/ 77.35	67.47/71.73	67.31/70.33	80.05 /75.74
CP(H)	73.63 /68.08	63.26/56.50	75.00/66.42	46.00/58.82	67.20/66.27	71.56/66.89	51.59/71.33	56.34/71.43
CP(I)	63.13/48.35	62.54/51.41	67.98/68.23	56.25/72.55	72.45/59.93	68.31/64.93	66.66/72.63	54.58/59.06
CP(J)	70.16/70.91	62.61/46.66	65.88/ 83.36	77.52/ 77.76	69.20/65.01	58.23/72.01	66.57/70.21	71.06/65.70
CP(K)	68.56/ 76.08	66.68/68.21	67.12/54.31	76.60/70.94	73.98 /72.25	44.30/ 78.25	68.77/72.04	71.55/69.03
CP(L)	71.70/52.87	49.16/44.58	77.98 /74.61	78.60/67.53	68.19/ 73.92	70.94/70.51	72.78 /58.57	64.52/66.34
Mean{CP}	67.40/65.35	59.26/60.89	66.05/69.05	70.39/70.99	67.65/66.73	66.75/68.91	66.69/68.84	67.75/68.87
提案法	73.53 / 75.87	71.87 / 71.55	76.75 / 84.62	77.22/ 78.86	78.55 / 80.36	77.93 / 78.55	79.49 / 78.85	79.71 / 80.09

表 2: 各テスト期間における F 値 [%] : Bid(左)/Ask(右). 各列において F 値が高い 3 位までを太字で示す.

テスト期間	9月5日	9月6日	9月7日	9月8日	9月12日	9月13日	9月14日	9月15日
CP(A)	6.07/45.45	73.82/63.18	64.43/63.72	59.14/74.22	69.13/60.02	67.10/71.31	63.44/51.69	74.65 / 85.14
CP(B)	0.44/67.24	71.95/ 73.77	57.32/31.18	65.58/1.19	61.45/66.63	68.10/72.40	0.00/0.00	0.00/0.00
CP(C)	31.21/65.79	70.33/48.77	68.21/ 76.89	17.57/69.05	34.18/40.93	41.81/40.26	69.97 /2.00	30.99/61.13
CP(D)	51.59/16.59	4.96/ 75.86	70.92 /74.78	83.96 /78.49	62.83/75.89	68.23 /73.09	63.81/0.85	68.59/63.72
CP(E)	85.67 / 69.69	70.46/70.91	64.26/ 75.42	81.06 / 84.36	74.67 / 77.81	11.60/ 78.91	56.20/25.07	77.31 /5.12
CP(F)	83.33 /40.00	47.47/36.52	63.00/56.22	9.41/72.22	68.27/59.87	40.97/69.09	71.23 /25.46	70.81/28.22
CP(G)	60.24/0.28	75.70 /73.73	28.93/ 79.15	19.72/ 84.45	71.40/74.98	43.54/13.24	62.48/45.62	77.21 /5.51
CP(H)	72.35/65.39	23.80/66.84	69.36/57.11	78.64/31.32	59.79/44.40	6.08/44.42	63.29/63.30	60.20/ 79.03
CP(I)	4.57/ 69.33	38.71/65.79	57.19/27.62	67.81/71.26	18.52/29.64	29.34/35.01	65.46/ 64.27	43.07/24.80
CP(J)	79.26/61.11	75.01/68.15	69.70/12.42	46.51/ 84.38	68.56/ 78.62	68.34 /8.24	7.59/15.13	74.39/76.01
CP(K)	25.93/29.88	77.03 /68.65	74.98 /63.20	84.96 /71.41	74.81 /72.64	55.37/67.36	50.04/ 77.70	73.33/ 87.36
CP(L)	66.67/60.71	52.65/69.25	62.98/71.65	72.78/37.62	54.39/47.05	45.97/ 74.79	39.19/47.25	52.58/46.67
Mean{CP}	47.28/49.29	56.82/65.12	62.61/57.45	57.26/63.33	59.83/60.71	45.54/54.01	51.06/34.86	58.59/46.89
提案法	79.73 / 78.00	77.91 / 76.89	76.25 /74.76	78.07/80.07	75.76 / 76.81	75.29 / 76.72	73.68 / 65.89	62.86/72.34

テスト期間	9月19日	9月20日	9月21日	9月22日	9月26日	9月27日	9月28日	9月29日
CP(A)	73.26 /72.68	56.50/32.47	81.77 /48.96	5.26/77.17	73.74/ 81.78	35.10/54.79	76.77/68.57	72.71/68.26
CP(B)	65.78/65.47	63.01/ 68.81	41.38/1.29	74.10/68.71	15.66/60.96	11.96/61.49	81.25 /62.42	53.71/73.77
CP(C)	37.18/52.17	31.17/68.78	0.18/10.87	66.76/ 78.79	34.91/57.46	76.20/62.81	26.56/48.11	28.85/12.37
CP(D)	57.32/65.09	65.92/67.01	45.45/14.63	55.17/45.83	69.72/32.26	77.48 / 75.48	67.08/5.00	80.20 /72.64
CP(E)	79.17 / 77.44	45.01/56.18	10.00/60.00	60.08/ 80.14	74.90 /70.10	86.15 /66.98	79.87 / 72.87	81.98 / 77.36
CP(F)	47.83/75.78	44.78/59.56	66.94/0.35	71.46/ 82.82	22.93/67.69	30.95/66.98	16.78/43.58	47.83/59.40
CP(G)	69.95/66.51	72.35 / 81.28	7.59/ 76.37	50.61/71.68	74.90 /77.14	68.81/46.25	64.57/54.63	50.33/48.59
CP(H)	57.95/ 79.71	75.10 /59.54	76.16 / 65.30	52.63/60.51	24.98/44.77	64.73/68.62	55.77/ 68.96	9.10/19.94
CP(I)	31.05/59.76	73.92 /55.74	80.83 /0.90	48.15/28.61	56.65/72.51	70.36/56.40	60.65/19.83	68.67/69.51
CP(J)	66.03/16.36	54.43/35.07	69.91/40.50	77.57 /71.97	69.58/ 77.67	18.54/65.35	71.31/19.44	73.27/76.27
CP(K)	14.11/ 80.43	57.32/12.42	25.00/60.74	74.32 /48.49	74.29/71.71	55.78/47.74	4.32/61.29	47.38/ 78.15
CP(L)	82.88 /62.36	42.46/34.52	1.00/58.00	1.86/64.08	71.41/25.75	48.29/ 69.66	8.70/27.18	36.64/68.35
Mean{CP}	56.88/64.48	56.83/52.62	42.18/36.49	53.16/64.90	55.31/61.65	53.70/61.88	51.14/45.99	54.22/60.38
提案法	72.66/75.34	71.27/ 70.74	71.87/ 84.03	76.90 /77.87	77.86 / 79.58	77.66 / 78.01	79.16 / 77.83	78.30 / 79.00

※「0.00」は予測値が全て $\pm\sigma$ の範囲内となり、不変と判別されたためである.

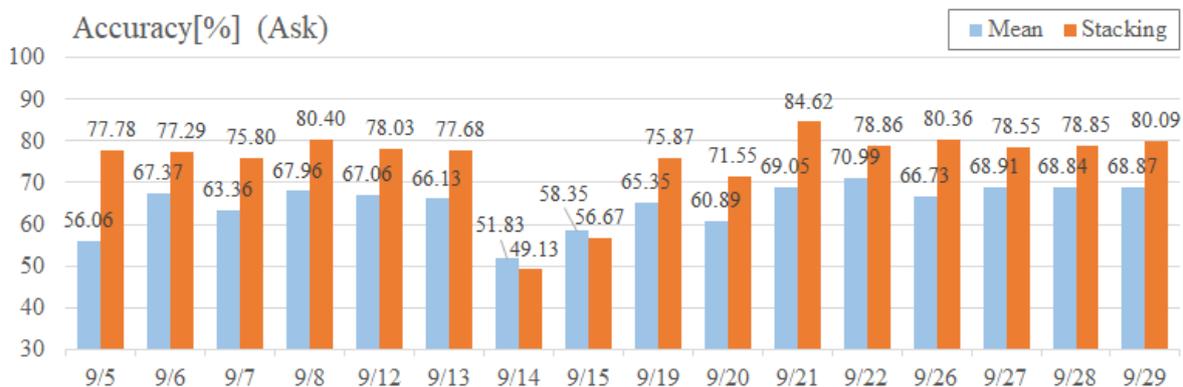
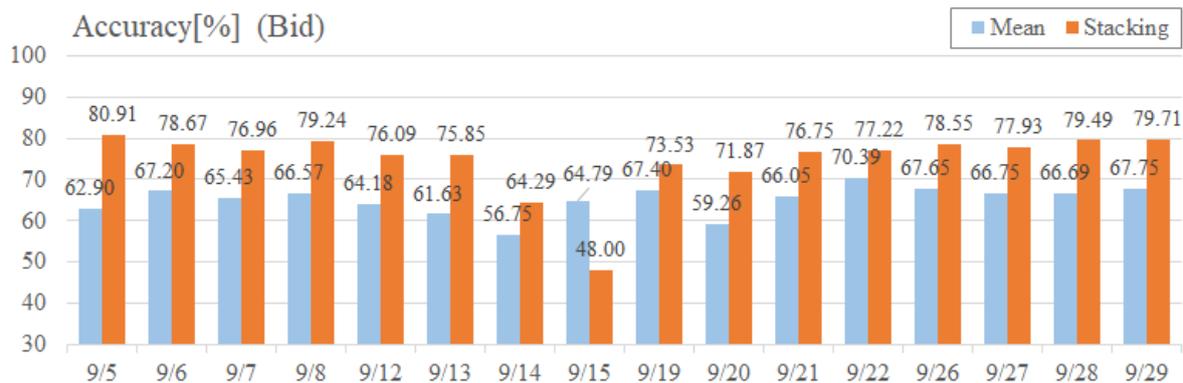


図 5: Mean(個別法 (平均値)) および Stacking(提案法) による Accuracy(正答率) の比較

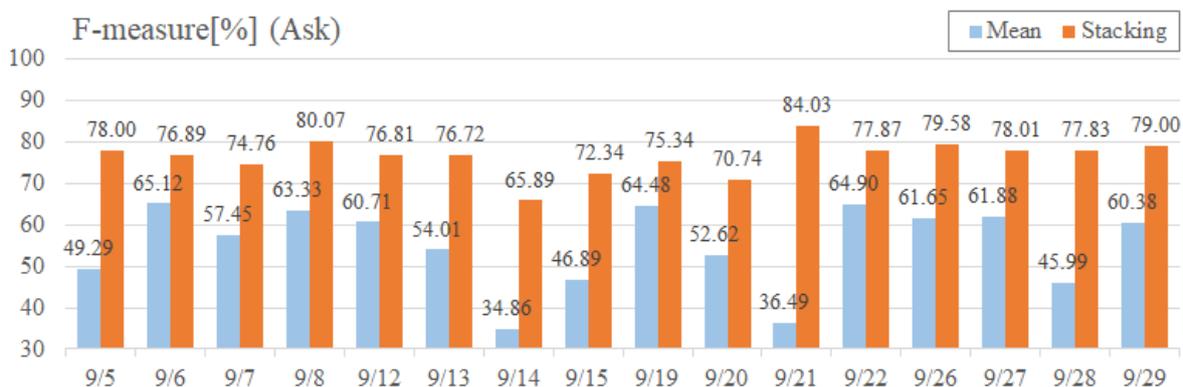
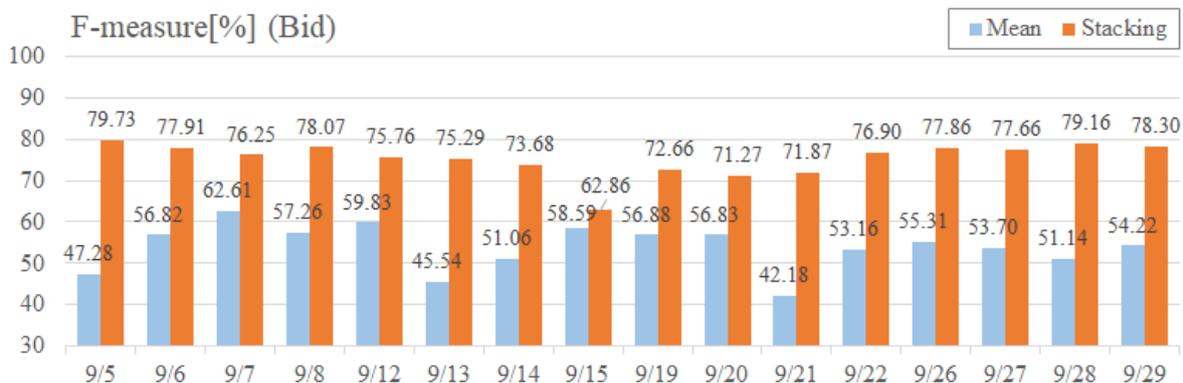


図 6: Mean(個別法 (平均値)) および Stacking(提案法) による F-measure(F 値) の比較

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

Development of Platforms for Investors using Financial Text Mining

坂地 泰紀^{1*} 和泉 潔¹ 松島 裕康¹
Hiroki Sakaji¹ Kiyoshi Izumi¹ Hiroyasu Matsushima¹

¹ 東京大学大学院工学系研究科
¹ Graduate School of Engineering, The University of Tokyo

Abstract: 近年、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应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を支援する技術が注目されている。特に、個人投資家・機関投資家を問わず、大量の情報の中から投資に有用な情報を抽出し、提示するシステムが求められている。そこで、我々は個人、もしくは、専門家が容易に新聞記事や決算短信などの金融テキストを分析できるテキスト解析プラットフォームを構築することを目指す。

1 はじめに

近年、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应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を支援する技術が注目されている。さらに、最近では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行う技術の必要性が高まっている。そのような中、酒井ら [酒井 15] は個人投資家支援のため、企業の決算短信 PDF から業績要因を抽出し、それを検索できるシステム¹を公開している。また、日本経済新聞社は人工知能技術を用いて決算データを自動的に要約して出力する AI 決算サマリー²を開発・公開している。このように、人工知能技術を投資家支援に用いた研究・開発は盛んである。

また、特許分野においては、株式会社 NTT データ数理システムが Text Mining Studio³を特許文書などを解析するテキストマイニングプラットフォームとして開発している。さらに、株式会社プラスアルファ・コンサルティングは、特許文書を専門とした解析プラットフォームである見える化エンジン Paterio⁴を開発している。このように、金融分野だけではなく、特許分野などの他の分野においても、特許分析支援のために文書を解析するシステムが開発されている。

上記で紹介したシステムやプラットフォームのい

れも、単語や表現の頻度、もしくは、係り関係を元に分析するものとなっている。それに対して、我々が作成した原因・結果表現検索システム⁵は、論理関係の一つである因果関係に基づき、原因と結果を表す表現を決算短信 PDF から抽出し、それを検索できるシステムである [坂地 15]。システムを図 1 に示す。単語や表現の頻度だけではなく、因果関係を利用することで、単語頻度だけでは得られない情報を得ることができる。例えば、「猛暑」という語で検索すること、原因表現として「猛暑の影響」、結果表現として「除草関連用品、散水用品、日除け用品が好調に推移しました」を見つけることができる。この結果から猛暑になると、除草関連用品が売れることを知ることができる。この結果の背後には、「猛暑により雑草が大きく成長する」という隠れた関係がある。我々は、このような思いがけないような因果関係を抽出する手法も提案している [Sakaji 17]。

このような中、我々は因果関係の原因と結果をつなげることで因果チェーン構築の試みを行っている [西村 18]。本論文では、原因・結果表現の抽出や因果関係の判定、因果チェーン検索機能などを持ったテキスト解析プラットフォームの構想について述べる。

2 テキスト解析プラットフォーム

本節では、我々が想定しているテキスト解析プラットフォームについて述べる。本テキスト解析プラットフォームでは、因果関係の抽出と判定、さらには因果をリンクさせて因果チェーンを構築し、それを利用した

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

¹<http://hawk.ci.seikei.ac.jp/cees/>

²<http://pr.nikkei.com/qreports-ai/>

³<https://www.msi.co.jp/tmstudio/aboutTMS.html>

⁴<http://www.pa-consul.co.jp/mieruka/scene/paterio.html>

⁵<http://socsim.t.u-tokyo.ac.jp/CS/>

検索などの機能を備える予定である。現在は、決算短信と日経新聞記事を用いた因果チェーン検索システムの開発を試みている。加えて、景気ウォッチャー調査を学習したモデル [余野 17] を用いた極性判定 API や、プラットフォームとは異なるがロイターニュース記事を学習して生成した極性辞書 [Ito 18] も公開予定である。極性辞書に関しては、金融特化の辞書となっているため、金融テキストの分析においては有効的な結果を示すことができている。

さらに我々は、過去の研究で用いた手法を Python パッケージにして公開する計画を立てている。これにより、お手軽に金融テキストマイニングを試すことができるようになり、実務に応用しやすくなると期待している。



図 1: 決算短信における因果関係検索システム

3 まとめ

本論文では、テキスト解析プラットフォームの構想について述べた。特に因果関係抽出を用いた因果チェーンの構築について紹介した。いくつかのシステムは既に実装・公開しており、今後は完成次第、順次公開していく予定である。

4 今後の展望

今後は、金融分野のテキストだけではなく、特許や Web ブログや掲示板などのテキストデータからも因果関係を抽出し、因果チェーンを構築したい。さらに、因果関係だけではなく、仮定や目的などの他の論理関係も扱えるように拡張する予定である。そのように拡張することで、分野横断論理チェーン (図 2) が構築でき、新しく作られる製品の予想などができるようになると期待できる。

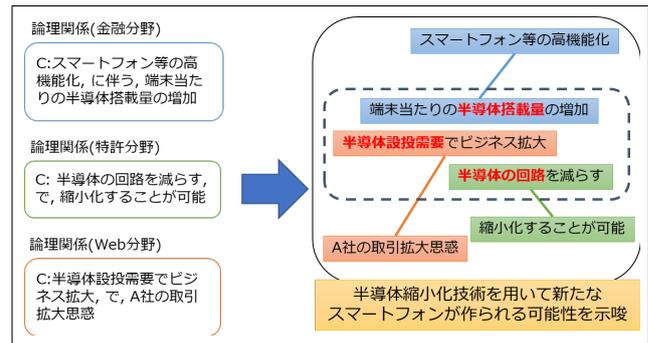


図 2: 分野横断論理チェーンの例

参考文献

[Ito 18] Ito, T., Sakaji, H., Tsubouchi, K., Izumi, K., and Yamashita, T.: Text-Visualizing Neural Network Model: Understanding Online Financial Textual Data, in *Pacific-Asia Conference on Knowledge Discovery and Data Mining*, pp. 247–259 Springer (2018)

[Sakaji 17] Sakaji, H., Muroto, R., Sakai, H., Bennett, J., and Izumi, K.: Discovery of Rare Causal Knowledge from Financial Statement Summaries, in *Proceedings of the 2017 IEEE Symposium on Computational Intelligence for Financial Engineering and Economics (CIFER)*, pp. 602–608 (2017)

[坂地 15] 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)

[酒井 15] 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. 39, No. 1, pp. 172–183 (2015)

[西村 18] 西村 弘平, 坂地 泰紀, 和泉 潔: 表現類似度を用いた因果ネットワークの構築, 2018 年度人工知能学会全国大会 (2018)

[余野 17] 余野 京登, 和泉 潔: 金融レポート、およびマクロ経済指数によるリアルタイム日銀センチメントの予測, 2017 年度人工知能学会全国大会 (2017)

有価証券報告書からの事業セグメントごとの 業績要因文・業績結果文の抽出

Extraction of causal and result information belong to business segments
from securities reports

高野 海斗¹ 酒井 浩之¹ 北島 良三¹

Kaito TAKANO¹, Hiroyuki SAKAI¹, and Ryoza KITAJIMA¹

¹成蹊大学 〒180-8633 東京都武蔵野市吉祥寺北町3-3-1

¹Seikei University 3-3-1 Kichijoji-Kitamachi, Musashino-shi, Tokyo, 180-8633

Abstract: In this research, we propose a method of extracting business segments from securities reports and extracting sentences including causal and result information concerning business performance for each extracted business segments. For example, our method extracts “In the aluminum rolled products business, shipments of high purity foils for aluminum electrolytic capacitors for industrial equipment and automotive use increased and sales increased.” as a sentence including causal information concerning business performance. Moreover, our method estimates that the sentence belongs to business segment “aluminum”. Our method extracts “As a result of this segment sales in this segment were 105,439 million yen, operating profit was 6,697 million yen.” as the result information belong to “aluminum” segment.

1. はじめに

近年、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、膨大な金融情報を分析して投資判断を支援する技術が注目されている。さらに、最近では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行う技術の必要性が高まっている[1][2][3]。

投資家が投資活動を行うにあたり、上場企業の業績情報の収集は必要不可欠である。また、業績情報の中でも特に業績要因が投資判断において重要である。なぜなら、業績回復の要因が、その企業の主力事業が好調であることであったならば株価への影響は大きい、株式売却益の計上などの特別利益の計上が要因であるならば株価への影響は軽微であるからである。

これまで、決算短信から業績要因の抽出は行われてきた[4][5]。しかし、決算短信は、上場企業が決算発表時に提出する決算速報であるため、タイムリーな情報が得られる反面、企業によってフォーマットが異なっていることが問題となる。特に、事業セグメントごとの業績情報は、企業ごとに表や文書のフォーマットが異なるため、事業セグメント名や事業セグメントごとの業績情報の抽出は困難である。

そこで本研究では有価証券報告書から事業セグメントごとの業績要因と業績結果の抽出を行う。有価証券報告書は、金融商品取引法で規定されており、審査を通す必要があることから、公表までに時間がかかる反面、決算短信と比較するとフォーマットが定まっている。また有価証券報告書のデータは、金融庁が運営している Web ページである EDINET[8]上に開示されているため、収集が容易である。

本研究では、事業セグメントごとの業績要因文を抽出し、さらに、業績結果と組み合わせることで、抽出された業績要因文がその企業の中でどの程度の重要性をもつかを判断するのに役立つと考える。例えば、株式会社 SUBARU では事業セグメントが「自動車」と「航空宇宙」の2つある。それぞれのセグメントごとの2016年3月31日から2017年4月1日までの利益は、図1.1からわかりように、「自動車セグメント」で397,657百万円、「航空宇宙セグメント」で9,102百万円となっており、大きな差がある。そのため、SUBARUにとって「自動車セグメント」の業績要因は「航空宇宙セグメント」の業績要因よりも重要であると考えられる。

当初は、事業セグメントごとの業績要因文と業績結果文が記載されている箇所（文の集合）を推定してから、業績要因文であるかどうかを分類しようと試みたが、企業や年度によってフォーマットが異な

るため、適合率・再現率に限界があった。そこで、本手法では、先に業績要因文であるかどうかの判定を行い、そこに事業セグメントを付与する。

関連研究として、村野らは企業の決算短信から自動抽出した業績要因文に対して、事業セグメントをk近傍法によって分類している[6]。しかし、村野らの手法を行うためには、人手で事業セグメント名を企業Webページや、決算短信から収集する必要がある。証券市場の上場企業数は東京証券取引所の上場企業だけでも2018年10月1日現在、3,635社も存在するため、人手で付与するには多大な労力が必要となる。それに対し、本研究で提案する手法は、ある程度フォーマットが定まっている有価証券報告書を用いることで、事業セグメント名を自動的に抽出し、人手による作業を必要としないものとなる。

	売上高				セグメント利益			
	2016年3月期	2017年3月期	増減	増減率	2016年3月期	2017年3月期	増減	増減率
自動車	3,039,424	3,151,961	112,537	3.7	543,609	397,657	△145,952	△26.8
航空宇宙	152,786	138,759	△14,027	△9.2	18,201	9,102	△9,099	△50.0
その他	40,048	35,272	△4,776	△11.9	2,998	3,512	514	17.1
調整額	-	-	-	-	781	539	△242	△31.0
合計	3,232,258	3,325,992	93,734	2.9	565,589	410,810	△154,779	△27.4

(注) 1. 売上高は、外部顧客への売上高であります。
2. セグメント利益の調整額は、セグメント間取引消去であります。

図 1.1. 株式会社 SUBARU H29 セグメント状況

2. 提案手法

本研究では、有価証券報告書から企業ごとの事業セグメント名とその事業セグメントに関する業績要因文・業績結果文を抽出する手法を提案する。以下に本手法の概要を示す。

- Step 1: 有価証券報告書の 1.5 節「従業員の状況」から、事業セグメント名の候補を抽出する。
- Step 2: 有価証券報告書の 2 章「事業の状況」から、文をすべて抽出し、業績要因文、業績結果文、それ以外の文に分類する。
- Step 3: Step 2 で抽出した業績要因文に対して、事業セグメントを付与し、その業績要因文に対応する業績結果文があれば、その業績結果文にも事業セグメントを付与する。
- Step 4: Step 3 で事業セグメントが付与できなかった業績要因文に対して、別のアプローチを用いて、事業セグメントを付与する。

2.1. 事業セグメント名候補の抽出

有価証券報告書の 1.5 節「従業員の状況」に事業セグメントごとの従業員数が記載されているため、この部分から事業セグメント名と思われる文字列を候補として抽出する。具体的には表中の「セグメント

の名称」と「合計」の間にある文字列を事業セグメント名の候補とする。

図 2.1 は昭和電工の有価証券報告書からの事業セグメント名候補抽出の例である。昭和電工は「石油化学」、「化学品」、「エレクトロニクス」などが事業セグメント名であり、それらが候補として抽出される。

セグメントの名称		従業員数 (名)
石油化学		406 (71)
化学品		1,234 (172)
エレクトロニクス		321 (127)
無属		251 (74)
アルミニウム		623 (271)
その他		781 (106)
合計		3,616 (821)

(注) 1 従業員数は従業員であり、社外への出向者を除き、社外から受け入れた出向者を含む。また、執行役員及びコーポレートフェローを含まない。
2 臨時雇用者数(契約社員、嘱託社員を含む。)は、当事業年度の平均人員を()外数で記載している。
3 平均年間給与は、賞与及び基準外賃金を含んでいる。
4 全社共通研究に係る従業員については、「その他」に含めて表示している。

(注) 3 労働組合の状況
当社は、昭和電工ユニオンがあり、本部を東京都港区に置いている。(平成29年12月31日現在組合員数2,832名。出向中の組合員を含まない。)
会社と昭和電工ユニオンとの間には、相対的平和義務を伴う労働協約が締結されており、友好的な関係を維持している。
連結子会社における労働組合の状況について特に記載すべき事項はない。

図 2.1. 事業セグメント名候補抽出の例

2.2. 業績要因文、業績結果文の抽出

有価証券報告書の 2 章「事業の状況」から文の集合を抽出する。次に、抽出した文集合を一文ずつ分類し、業績要因文と業績結果文を抽出する。分類は文が業績要因文であるかどうかの 2 値分類と、業績結果文であるかどうかの 2 値分類を異なる手法を用いて行う。

①業績要因文であるかどうかの分類

業績要因文の分類は深層学習を用いて行った。深層学習のための学習データは酒井らの手法[7]により自動的に生成した。酒井らの手法の概要と、業績要因文の判定は以下のとおりである。

- Step 1: 酒井らの手法[5]を用いて、決算短信から業績要因文、手がかり表現、後述の企業キーワードを抽出する。
- Step 2: Step 1 で抽出された手がかり表現の“拡張手がかり表現”を獲得する。
- Step 3: Step 1 で抽出された業績要因文に対して、企業キーワードを用いてスコアを付与する。
- Step 4: 拡張手がかり表現を含み、かつ、スコアが高い業績要因文を正例とし、手がかり表現、企業

キーワードをともに含まない文を負例として学習データを自動生成する。

Step 5: 自動生成された学習データを使用し、深層学習にて有価証券報告書から抽出した事業セグメントに対応する文集合に対して、1文ごとに業績要因文を判定する

ここで、企業キーワードとはその企業にとって重要なキーワードのことを示しており、以下の式を用いて、名詞に重み付けを行い、重みが大きい名詞を対象とする。

$$W(n_i, S(t)) = Tf(n_i, S(t)) \times H(n_i, S(t)) \times idf(n_i)$$

$S(t)$: 企業 t の決算短信の集合。

$Tf(n_i, S(t))$: $S(t)$ において名詞 n_i が出現する頻度。

$H(n_i, S(t))$: $S(t)$ の要素である決算短信に名詞 n_i が出現する確率に基づくエントロピー。

深層学習のモデルは多層パーセプトロンを採用し、隠れ層は、順にノード数 3,000 が 3 層、ノード数 1,000 が 3 層、ノード数 500 が 3 層、ノード数 100 が 3 層の計 12 層とした。出力層は 1 要素である。また、epoch 数は 20、活性化関数として ReLU を使用した。

さらに、深層学習によって業績要因文と判定された文集合から、上述の企業キーワード抽出のための名詞の重み付けの式を用いて企業キーワードを新たに抽出し、業績要因文は新たに抽出した企業キーワードを含むものに限定した。

②業績結果文であるかどうかの分類

ルールベースで「億円」「万円」「千円」などを含む文とし分類を行った。ただし、このルールだけでは業績結果文ではない文も多く業績結果文として誤分類してしまうため、2.3 節で述べる事業セグメントの付与において、業績要因文との関係に基づき業績結果文を確定させる。

2.3. 事業セグメントの付与

2.2 節で抽出した業績要因文と業績結果文に対して、2.1 節で獲得した事業セグメント名の候補を用いて、事業セグメントの付与を行う。付与の手法は以下のとおりである。

① 文の位置による付与

有価証券報告書の 2 章「事業の状況」を上から 1 文ごとに取得する。「。」を含まない文であれば、事業セグメント名の候補を含んでいるかどうか確認する。事業セグメント名候補を含んでいれば、そこか

ら 5 行以内に出てきた文は、その事業セグメントの内容であると判定する。5 行以内に業績要因文や業績結果文と判定された文が取得された場合、そこから新たに 5 行以内に出てきた文は、その事業セグメントの内容であると判定する。

具体的には、表 2.2 の例だと、26 行目の行が「。」を含まない文であり、「コンサルティング」が事業セグメント名候補として抽出できているため、以下 5 行の 31 行目までは「コンサルティング」事業の文であると判定する。31 行目の文は業績結果文であるため、さらに以下 5 行の 36 行目までは「コンサルティング」事業の文であると判定される。しかし、32 行目の行が「。」を含まない文であり、「金融 IT ソリューション」が事業セグメント名候補として抽出できているため、32 行目から以下 5 行の 37 行目までは、「金融 IT ソリューション」事業の文であると判定が上書きされる。35 行目の文は業績結果文であるため、さらに以下 5 行の 40 行目までは「金融 IT ソリューション」事業の文であると判定される。

手法①での事業セグメントの付与は、適合率が高いものの、フォーマットの関係などで事業セグメントが付与できていない業績要因文が多く存在する。そこで、①で付与できなかった業績要因文に対して以下のアプローチで事業セグメントの付与を行った。

② ルールベースによる付与

まず、第一段階として、xbrl ファイルからテキストを抽出する際に、事業セグメント名と事業セグメントに対応する文が一つになってしまい、事業セグメントの付与ができない原因に対応した。

例えば、「アルミニウム」、「当セグメントでは、アルミ電解コンデンサ…」のように行が分かれてテキストを抽出することを想定しているが、この抽出が「アルミニウム当セグメントでは、アルミ電解コンデンサ…」のように 1 行になって抽出してしまうことが起こっている。そこで、行の先頭、1 文字削除した箇所、2 文字削除した箇所、3 文字削除した箇所に対して、事業セグメント名の候補があるかどうかでセグメントの付与を行った。1 文字～3 文字削除した箇所に関しては、「①アルミニウム当セグメント…」や「(1)アルミニウム当セグメント…」に対応するためである。これにより、新たに 20621 の業績要因文に事業セグメントを付与することができた。

表 2.2. 野村総合研究所の業績要因文・業績結果文へのセグメント付与例

行数	業績要因	業績結果
26		(コンサルティング)
27		当セグメントは、政策提言や戦略コンサルティング、業務改革をサポートする業務コンサルティング、ITマネジメント全般にわたるシステムコンサルティングを提供しています。
28		顧客の経営環境やIT部門の環境が変化中、経営・ITの両面でコンサルティングの需要が高まっています。
29	○	当社グループは、顧客のビジネス全般を支援する変革パートナーとなる体制を整えていくとともに、海外も含めた顧客基盤の拡大に努めました。
30	○	当年度は、企業収益の改善を受け、顧客業務の実行を支援する業務コンサルティングなどが増加したことに加え、グローバル関連ではASGGroupLimitedがシステムコンサルティングの増加に寄与しました。
31	○	この結果、売上高31,161百万円(前年度比8.1%増)、営業利益5,853百万円(同6.7%増)となりました。
32		(金融ITソリューション)
33		当セグメントは、主に証券業や保険業、銀行業等の金融業顧客向けに、システムコンサルティング、システム開発及び運用サービスの提供、共同利用型システム等のITソリューションの提供を行っています。
34		事業領域の拡大に向け、業界標準ビジネスプラットフォームの生産革新を進めるとともに、ITと金融を融合したFinTech(フィンテック)等を活用した新事業の開発に取り組んでいます。
35	○	既存事業の拡大に向けた取組みとして、業界標準ビジネスプラットフォームについては、制度改正への着実な対応を進めるとともに、顧客業務の高度化や効率化の支援を進めました。
36		リテール証券のバックオフィス業務をサポートする共同利用型システム「STAR-IV」については、災害時にシステム障害復旧を行う機能を追加したサービスを提供しています。
37		また、平成30年に実施予定の国債の決済期間短縮化や、証券保管振替機構の次期システムへの移行について、当社の共同利用型システムの対応を進めています。
38	○	また、資産運用領域の事業拡大を目的に、米国のCutterAssociates,LLCを子会社としました。
39	○	○ 当年度の売上高は、証券業を中心にシステムコンサルティングが増加しましたが、前年度に大型の製品販売があった証券業向け開発・製品販売や、保険業向け開発・製品販売が減少し、248,188百万円(前年度比2.2%減)となりました。
40	○	○ 子会社の(株)だいこう証券ビジネスにおいて業務体制見直しに向けた事業構造改善費用を計上したこともあり、営業利益は26,461百万円(同9.3%減)となりました。

③最近傍法による分類

ここまでに事業セグメントが付与できた業績要因文を用いて、まだ事業セグメントが付与できていない業績要因文とのコサイン類似度を計算し、コサイン類似度が一番高い業績要因文と同様の事業セグメントを付与した。コサイン類似度の計算は、業績要因文から新たに獲得した企業キーワードを要素、企業キーワードの重みを要素値とした単語ベクトルで計算した。

これにより、新たに 42375 の業績要因文に事業セグメントを付与することができた。

3. 実装

本手法を実装し、キーワードによって業績要因文を検索できる有価証券報告書検索システムを作成した¹。使用するデータは EDINET から取得した有価証券報告書の xbrl ファイル (21,324 個) を用いた。

図 3.1 に「燃料電池」で検索した場合の検索結果を示す。アルミニウムを含む業績要因文と企業名、その業績要因文に付与された事業セグメント名、さらに、その事業セグメントの業績文が表示される。



図 3.1 「燃料電池」での検索結果

4. 評価

業績結果文であるかどうかの分類精度の評価は、事業セグメントを 5 つ以上持つ企業をランダムに 10 社、選択し、選択した 10 社の有価証券報告書から抽出された業績要因文 83 文を人手にて正解を判定して精度を計算した。また、事業セグメント付与の精

¹ <http://hawk.ci.seikei.ac.jp/u-cees/>

度は、業績要因文の判定が正しかったもののうち、正しい事業セグメントに分類されているかどうかで評価を行った。その結果を表 4.1 に示す。

表 4.1. 評価結果

企業名	業績要因文の分類精度	事業セグメント付与の精度1	事業セグメント付与の精度2
太洋工業株式会社	1.00	1.00	0.56
株式会社ウィルグループ	0.86	1.00	1.00
東京都競馬株式会社	0.89	1.00	0.88
日本プロセス株式会社	0.88	1.00	0.86
株式会社ハウズドゥ	0.88	1.00	0.71
ユアサ商事株式会社	0.91	1.00	0.70
パーソルホールディングス株式会社	1.00	1.00	0.80
東洋インキSCホールディングス株式会社	1.00	1.00	1.00
ナカバヤシ株式会社	1.00	1.00	1.00
九州旅客鉄道株式会社	0.70	1.00	0.71
平均	0.91	1.00	0.82

事業セグメント付与の精度 1 と 2 の違いは、「鏡面研磨機事業の販売は増加したものの、電子基板事業におけるディスプレイメーカー向けの受注の減少、並びに商社事業及び基板検査機事業の販売が減少したことから、売上高が減少いたしました。」のような企業全体の業績要因文に対して、文に含まれているどこかの事業セグメントが付与されているものを、分類が合っているとしたものが精度 1 であり、分類が間違っているとしたものが精度 2 である。

5. 考察と今後の方針

最近傍法を用いることで、事業セグメントの付与ができた文がある反面、企業全体のことについて記載されている部分に事業セグメントが付与されてしまった。今後は企業全体のことについて記載されているかどうかを推定する必要もある。

業績要因文の分類精度は高い結果となった。誤った業績要因文については、「合意しました」などの文が含まれていた。再現率はまだ測定していないため、今後正解データを作成し測定していく。

事業セグメントごとの業績要因文と業績結果文は、有価証券報告書にまとまって出現するため、今後は事業セグメントごとの記述が記載されている部分を推定していくことで、フォーマットが多少異なっている企業に対しても、抽出ができるようにしていきたい。また、本手法で取得できた事業セグメント名を用いることで、決算短信で抽出した業績要因文に対しても、事業セグメント名を付与できる可能性が高い。

今回自動で取得したデータは、業績要因文と業績結果文であるが、業績要因文の要因には、天候、原材料の価値変化、社会システムの変更、商品需要の

変化など様々な要因があるため、それらを分析することにも価値があると考ええる。また、業績結果文は売上や営業利益等を数値データに変換し、時系列での解析や、全体の売上や営業利益との割合で、その業績要因の重要度を定量的に推定することも可能である。今後は取得したデータの解析も行い、その結果をアウトプットできるようにする予定である。また、有価証券報告書には業績以外にも「事業の内容」、「企業の対処すべき課題」、「事業等のリスク」、「研究開発活動」など企業に関する重要な情報が多く記載されているため、これらを自動で抽出することで、様々な解析を行っていく予定である。

6. むすび

本研究では、これまで決算短信からは抽出することができなかった事業セグメントごとの業績要因文と業績結果文の抽出を有価証券報告書から行った。その結果、業績要因文の分類精度は 0.91 であり、事業セグメントの付与も良好であった。

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”, 情処学論, vol.52, no.12, pp.3309-3315, (2011)
- [2] 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)
- [3] 酒井浩之, 増山 繁, “企業の業績発表記事からの重要業績要因の抽出”, 信学論 (D), vol.J96-D, no.11, pp.2866- 2870, (2013)
- [4] 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)
- [5] 酒井浩之, 西沢裕子, 松並祥吾, 坂地泰紀, “企業の決算短信 PDF からの業績要因の抽出”, 人工知能学会論文誌, vol.30, no.1, pp.172-182, (2015)
- [6] 村野壮人, 酒井浩之, 坂地泰紀, 江口潤一, “決算短信から抽出した業績要因文の事業セグメントに基づく分類と業績文の抽出企業の決算短信 PDF からの業績要因の抽出”, 第 19 回金融情報学研究会, pp.59-64, (2017)
- [7] 酒井浩之, 松下和暉, “決算短信からの業績要因文の抽出”, 第 11 回テキストアナリティクス・シンポジウム, pp.87-91, (2017)
- [8] EDINET, <http://disclosure.edinet-fsa.go.jp>

適時開示情報の業績に対するリスク有無の自動判定

Automatic classification according to risk to the corporate performance
contained in timely disclosures of company information

矢野 大輔¹ 酒井 浩之¹ 北島 良三¹

広井 康男² 村山 勉² 河合 継³ 西山 昇⁴

Daisuke Yano¹, Hiroyuki Sakai¹, Ryoza Kitajima¹

Yasuo Hiroi², Tsutomu Murayama², Kei Kawai³, Noboru Nishiyama⁴

¹ 成蹊大学

¹ Seikei University

² 株式会社 QUICK

² QUICK Corp.

³ クリスタルメソッド株式会社

³ Crystal method co. ltd

⁴ Dragons' Desk Limited / 千葉商科大学

⁴ Dragons' Desk Limited / Chiba University of Commerce

Abstract:

In this paper, we propose a method for classifying timely disclosures of company information with risk to the corporate performance by using deep learning. For example, our method classifies a timely disclosure “A notice of recording an extraordinary loss” as “Including risk”. Moreover, our method classifies the timely disclosure as “Extraordinary loss”. Our method makes timely disclosures of company information easy to see and investors will be useful to make investment decisions. We evaluate our method and it attained 87.4% accuracy.

1. はじめに

近年、個人投資家の数が増加している中、適時開示情報への関心が高まっている。適時開示情報とは上場企業が義務付けられている「重要な会社情報の開示」のことであり、適時開示情報の中には、その上場企業の株価に影響を与える可能性の情報もある。特に、例えば「業績予想の修正」や「営業停止処分」といった業績にリスクのある情報は株価への影響も大きく、投資判断にも大きな影響を与える。

しかし、適時開示情報はインターネット上でいつでも閲覧できるが¹、常に新しい情報が掲載され続けているため、すべてを閲覧することは困難であり、さらに、その中から業績にリスクのある情報のみを判別して閲覧することは多大な労力を必要とする。

そこで、本研究では、上場企業が公開する適時開

示情報を、深層学習によって業績にリスクがあると考えられる情報のみを自動で抽出し、それらを分類する手法を提案する。例えば、「業績予想の修正に関するお知らせ」の適時開示情報を「リスクあり」と判定し、「特別損失」に分類する。

本研究により、業績にリスクのある適時開示情報の閲覧を容易にし、投資家の投資判断に役立てることを目的とする。

関連研究として、例えば、企業の発行している「決算短信」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行われている[1][2][3][4][5]。酒井らは企業の決算短信 PDF から業績要因文を自動抽出する研究を行っている[1]が、業績要因のみでは、業績に対するリスクを判断することはできない。それに対して、本研究ではリスクの有無を判定できる点が異なる。

¹ <https://www.jpx.co.jp/listing/disclosure/index.html>

2. 提案手法

2.1. 手法概要

- Step1: 適時開示情報の中から業績にリスクがあると考えられる情報を人手で抽出して学習データとし、その学習データを後述のワードリスト（表1）に示す語により分類する
- Step2: 学習データ・テストデータを適時開示情報の文書ごとに Doc2Vec によりベクトル化する
- Step3: 深層学習におけるモデルの最適な中間層や batch を決定する
- Step4: Chainer を用いて学習データを用いて学習を行い、Chainer のモデルを作成する
- Step5: 作成されたモデルに基づき、リスクがある文書をリスクあり、リスクなしに分類し、さらに、リスクありと判定された文書を、その内容に基づいて分類する。

2.2. 使用するデータ

学習データには 2017 年の適時開示情報を使用し、テストデータには 2016 年の適時開示情報を使用する。

学習データの作成方法を以下に述べる。表1に示したワードリストにある語が含まれている文書を「リスクあり」とし、含まれていない単語を「リスクなし」とする²。次に「リスクあり」とした文書の中から「特別損失」、「違反」、「その他」の3種類に分類する。「その他」には「火災」、「訴訟」、「損害」といった情報が含まれている。分類には表2に示されている語とラベル名に基づいて分類している。分類した学習データの構成を表4に示す。

表1 ワードリスト（一部）

災害, 紛争, テロ, 地震, 風水害, 疫病, パンデミック, 国際紛争, 訴訟, 法改正, 知的財産侵害, 事件, 事故, 不正, 金融犯罪, コンダクトリスク, (以下略 全99個)
--

表2 ラベル名の設定

ラベル名	含まれている語（一部）
特別損失	特別損失, 減損損失
違反	違反, 不正
その他	災害, 紛争, 訴訟
リスクなし	/

表3 学習データの構成

ラベル名	文書数
特別損失	164
違反	85
その他	73
負例	453
合計	775

以下に、各ラベルに付与された、学習データにおける文書の表題の例を示す。

特別損失	特別損失（有価証券評価損）の計上に関するお知らせ
	固定資産の減損処理に伴う特別損失の計上に関するお知らせ
違反	建設業法に基づく営業停止処分について
その他	当社連結子会社の火災事故に関するお知らせ
	米国外たばこ事業の買収完了について
	連結業績予想の修正に関するお知らせ
	当社に対する訴訟の提起に関するお知らせ
リスクなし	連結子会社における販売用不動産の売却に関するお知らせ
	株式分割による1株に満たない端数処理にともなう自己株式の買い取りに関するお知らせ

² 表1のワードリストは適時開示情報からのリスク情報の判定に経験のある人が作成した。

表4 テストデータの構成

ラベル名	文書数
特別損失	165
違反	85
その他	75
リスクなし	454
合計	779

2.3. 深層学習に使用するモデル

Chainer によって学習データからモデルを作成する。中間層を決定する上で適したモデルを作成するために、次のような手順を考える。モデルには、

「入力層 → X → X → X → 出力層」

となる多層パーセプトロンを用いる。

- Step1: epoch を 30 とし中間層 X のユニット数を変化させて、テストデータにおける精度を比較する
- Step2: 最適な中間層 X におけるユニット数を中間層に使用する
- Step3: batch の値を変化させて、テストデータにおける精度を比較する
- Step4: 最適な batch の値を使用する

表5 X の値ごとの精度比較

X	epoch	学習データにおける精度	テストデータにおける精度
10	100	0.92	0.83
100	100	0.99	0.88
200	100	0.99	0.88
500	100	0.99	0.88
800	100	1.00	0.89
1000	100	1.00	0.88

表6 batch ごとの精度比較

batch	epoch	学習データにおける精度	テストデータにおける精度
10	30	1.00	0.89
50	151	1.00	0.90
100	200	0.99	0.88
200	200	0.97	0.89
400	400	0.97	0.88
600	600	0.96	0.89

表5・表6によると X や batch の変化によって精度に大きな違いは見られなかった。そのため使用する

中間層 X のユニット数は、過学習を避けるため最も早く「学習データにおける精度」が 1 になった 800 を使用し、batch には同様の理由で 50 を使用することにした。

入力層は Doc2Vec によって Wikipedia から約 500MB の記事を次元数 400 で学習させたモデルに基づき、学習データの文書をベクトル化したベクトルを使用する。学習データではなく Wikipedia を使用した理由は、学習データのみでは Doc2Vec の学習に必要な十分なデータがなかったためである。出力層は (2. 2) により分類ラベル数の 4 とした。活性化関数には ReLU 関数を使用した。

表7 活性化関数比較

活性化関数	学習データにおける精度
ReLU	0.90
tanh	0.88
sigmoid	0.65

3. 評価

本手法の評価を行った。評価用の正解データは、テストデータとした 2016 年の適時開示情報から、表 1 で示したワードリストに基づき作成した。表 4 にテストデータの構成を示す。

分類の評価結果を表 8・表 9 に示す。分類の全体精度は 87.4% であった。

表8 分類結果の精度

ラベル	精度
特別損失	95.2%
違反	88.2%
その他	74.7%
リスクなし	89.4%
全体	87.4%

最も低い精度であったラベルは「その他」で 74.7%、最も高い精度であったラベルは「特別損失」で 95.2% であった。これは、「特別損失」の文書の特徴は掴めているが、「その他」は特徴が掴みづらかったと言える。

以下に、本手法によって「リスクあり」と判定された適時開示情報の例を表 9 に示す。

表9 「リスクあり」と判定された
適時開示情報の例

	抽出された記事の例
特別損失	特別損失の計上に関するお知らせ 当社は、平成29年9月期第1四半期決算において、特別損失を計上する必要が生じたので、お知らせいたします。
違反	公正取引委員会からの排除措置命令について本日、当社は公正取引委員会から防衛装備庁が発注する特定ビニロン製品の入札に関して独占禁止法に違反する行為があったとして、下記のとおり排除措置命令を受けました。
その他	インドネシア子会社の火災発生に関するお知らせ 当社の連結子会社であるPT.TOTOKUINDONESIAに隣接する他社工場で火災が発生し、その影響でトウトクインドネシアの工場が類焼しました。
リスクなし	組織改定ならびに執行役の管掌変更に関するお知らせ当社は、平成29年1月31日開催の取締役会において、下記のとおり組織改定ならびに執行役の管掌変更を行いましたのでお知らせいたします。

4. 考察

表8より、各ラベルとも精度が80%を超えており、良好な精度を達成しているが、「その他」における精度が74.7%と低い結果となっている。これは「その他」には「火災」や「損害」に関する文書など様々な文書が含まれているため、区分の幅が広がってしまったためであると考えられる。

一方で、「リスクなし」の精度は89.4%と高い精度が得られており、「リスクあり」と「リスクなし」の分類は高い精度で分類できているということが言える。

本手法により、ワードリストで設定した語が含まれていないにもかかわらず、正しく「リスクあり」と判定された例があった。以下に例を示す。

・「リスクあり」と判定した例

(略) 損益の状況<連結決算の概況>平成29年3月期第3四半期決算総括1 実質業務純益<1>は、連結子会社からの利益寄与が増加した一方、単体の資金関連利益の減少等により、前年同期比205億円減益(略)

これは表1のワードリストに載っているワードは含まれていないが、類似する単語を抽出して分類できたものであると考えられる。

・「リスクなし」と判定した例

平成28年1月5日にノースカロライナ州ナッシュ郡ロッキーマウントのゲートウェイブルバード200に位置するホテルで発生した火災に関して、(略) 今後の見通し本件和解金は損害保険により支払われるため、当社には財務上の負担はなく、平成30年3月期連結業績への影響はありません。

これは「火災」という単語が含まれているが、負例と判定している。

以上のようにワードリストの単語による抽出では得られないような文書を、「リスクあり」の文書の特徴を学習することによって正しく分類ができているということが分かった。

5. むすび

本研究では、深層学習によって適時開示情報を「特別損失」「違反」「その他」「リスクなし」の4種類に分類する手法を提案した。評価の結果として全体精度は87.4%であったが、ワードリストの単語の有無に関わらずに文書の特徴を学習することができていたことが分かった。また本研究の分類器を実際の業務に適用することを考える際に、「リスクあり」である適時開示情報を「リスクなし」と判断してしまったり、「リスクなし」であるものを「リスクあり」と判断してしまうことは大きな問題である。そのためリスクの有無の分類が非常に重要な点であるが、本研究では「リスクなし」における精度が89.4%と高い精度を得ることができた。

本研究では、適時開示情報からリスクの有無を自動判別する手法の提案であったが、実務への応用を考慮すると、判別されたリスクが当該企業以外に派生するリスクを同時に把握することが求められると考える。つまり、企業活動に重要な影響を与える内容を含んだ発表文書の内容に応じ、さらに当該発表

企業と取引関係、資本関係、競業関係等、影響が及ぶと思われる関連先企業をその関係性を含め抽出することができれば実務への応用が期待できる。

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] Shiori Kitamori, Hiroyuki Sakai, Hiroki Sakaji, “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 (IEEE CIFE'17), Hawaii, November, 2017.
- [4] 酒井浩之, 松下和暉, “決算短信からの業績要因文の抽出”, 第 11 回テキストアナリティクス・シンポジウム, pp.87-91, 2017.
- [5] Hiroki Sakaji, Risa Murono, Hiroyuki Sakai, Jason Bennett, Kiyoshi Izumi, “Discovery of Rare Causal Knowledge from Financial Statement Summaries”, IEEE Symposium on Computational Intelligence for Financial Engineering & Economics (IEEE CIFE'17), Hawaii, November, 2017.
- [6] TDnet 適時開示情報閲覧サービス, 2018 アクセス https://www.release.tdnet.info/inbs/1_main_00.html

決算短信における業績要因・業績結果の因果関係の抽出

Extraction of causal relation between performance factors and performance results from summaries of financial statements

加藤悠太¹ 酒井浩之¹ 坂地泰紀² 北島良三¹ 江口潤一³

Yuta Kato¹, Hiroyuki Sakai¹, Hiroki Sakaji², Ryoza Kitajima¹, Junichi Eguchi³

¹成蹊大学 理工学研究科 理工学専攻

¹Department of Computer and Information Science, Faculty of Science and Technology,
Seikei University

²東京大学

²The University of Tokyo

³大和証券投資信託株式会社

³Daiwa Asset Management

Abstract: In this paper, we propose a method for extracting causal relation between performance factors and performance results from summaries of financial statements by deep learning. For example, our method extracts “Sales of copper tubes for air conditioners declined due to high demand due to the hot summer heat caused by the hot summer of the year” as a performance factor, and “Consolidated operating profit was 4,859 million yen” as a performance result corresponding to the performance factor. By extracting such causal relation, it is possible to analyze what kind of factors have changed the performance.

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、個人投資判断を支援する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いる[1][4][5]。

例えば、決算短信から原因・結果表現を抽出する技術が提案されている[1]。既存手法[1]では、例えば、原因「猛暑」、結果「冷房需要の盛り上がり」といった情報を投資家に提示することで、「猛暑」の場合には、「冷房需要」が高まる可能性があることを個人投資家が知ることができる。しかし、既存手法[1]は原因・結果表現を抽出するための手がかり表現と Pattern を定義し、その Pattern に当てはまる原因・結果表現をすべて抽出する手法であるため、原因・結果表現ではあるが投資判断の支援とは無関係な情報も多く抽出されてしまう。

そこで、本研究では、決算短信から業績要因とその業績結果の因果関係の情報を含む文を抽出することを目的とする。例えば、業績要因「一昨年の猛暑の影響による高需要の反動によりエアコン用銅管の

売り上げが減少した。」、その業績結果「連結営業利益は4,859百万円（前連結会計年度比19.5%減）に留まりました。」という情報が含まれている文（業績要因文・業績結果文）を抽出する。この情報を大量の決算短信から自動的に抽出することで、ある要因の場合は業績が好調と言った企業を検索することが可能になる。

関連研究として、酒井らは手がかり表現と企業ごとの重要なキーワードを用いて決算短信から業績要因を抽出する手法を提案している[6]。さらに、文献[6]で抽出された業績要因文を用いて学習データを自動生成し、自動生成された学習データからより多くの業績要因文を抽出する手法を提案している[4]。しかし、酒井らの手法では業績要因を抽出できるが、それに対応する業績結果を取得しておらず、業績要因と業績結果の因果関係を得ることはできない。また、室野らは、既存手法[1]の結果から、意外性のある原因・結果表現を判定する手法を提案している[7][8]。それに対して本研究では、既存手法[1]の結果を業績要因・業績結果でさらに絞り込み、より高い精度を高めることを目的としている。

本手法では、既存手法を用いて決算短信から原因・

結果表現を抽出する。その中から、原因表現が業績要因であるもの、結果表現が業績結果であるものを、深層学習を用いて判別する。

2. 決算短信からの原因・結果表現の抽出

本手法では既存手法[1]の決算短信 PDF から抽出された原因・結果表現に対し、業績要因であるか、業績結果であるかを判定する。その既存手法[1]である原因・結果表現の抽出の概要を以下に示す。

2.1. 原因・結果表現の抽出の概要

- Step 1 : 各企業サイトから決算短信 PDF を収集し、収集した PDF をテキストに変換する。
- Step 2 : 得られたテキストデータから、原因・結果判定手法[2]を用い、原因・結果を含む文を抽出する。
- Step 3 : 原因・結果を含んでいると判定された文から、手がかり表現と構文情報を用いた Pattern を使用して原因を示す原因表現と結果を示す結果表現の対を抽出する。

2.2. 原因・結果を含む文の抽出

原因・結果を抽出するうえで重要な手がかりとなる表現を利用し、原因・結果を抽出する。

まず、半教師あり学習を用いたフィルタリング手法[2]を適用し、原因・結果を含む文を決算短信 PDF から抽出する。原因・結果を含む文を抽出する手法は SVM を用いるため、表 1 で説明する素性を使用している。

表 1 素性の一覧

構文的な素性
・ 助詞のペア
意味的な素性
・ 拡張言語オントロジー
上記以外の素性
・ 手がかり表現の直前形態素の品詞
・ 文に含まれる手がかり表現
・ 形態素ユニグラム
・ 形態素バイグラム

2.3. 原因・結果表現の抽出

手がかり表現を利用し、原因・結果を含む文集合から原因・結果表現を自動的に抽出する。文献[3]に

準拠し、原因・結果表現は出来事とその理由の組み合わせから構成されるとするが、既存研究[1]では 1 文中、または隣り合う 2 文中に直接表現されている表層的なものに限定する。原因・結果表現を抽出するための構文 Pattern や手がかり表現など、具体的な抽出手法については文献[1]を参照されたい。

3. 業績要因・業績結果判定のための学習データの生成

本手法では、既存手法[1]によって決算短信から抽出された原因・結果表現、それぞれから、業績要因、業績結果を深層学習にて判定する。深層学習による業績要因、業績結果それぞれの判定モデルを生成するため、学習データが必要となる。その学習データは自動生成するが、その業績要因文の学習データの生成手法[4]を以下に示す。

3.1. 業績要因抽出のための手がかり表現

酒井らの手法[6]では、業績要因抽出のための手がかり表現を決算短信から自動的に獲得する。手がかり表現は以下の手法で獲得される。

- Step 1 : 少数の手がかり表現（「が好調」、「が不振」）を人手で与え、それに係る節を取得する。
- Step 2 : 取得した節の集合から、その中で共通して頻繁に出現する表現（「売り上げ」等）を共通頻出表現として抽出する。
- Step 3 : 共通頻出表現に係る節を取得し、その中から新たな手がかり表現を抽出する。
- Step 4 : 獲得した手がかり表現から、それに係る共通頻出表現を取得する。
- Step 5 : Step 2 から Step 4 を、新たな手がかり表現と共通頻出表現が獲得されなくなる。もしくは、予め定めた回数まで繰り返す。

具体的な手がかり表現の獲得手法については、文献[6]を参照されたい。

3.2. 業績要因の学習データの自動生成

獲得された手がかり表現を拡張した手がかり表現（拡張手がかり表現と定義）と、企業ごとの重要なキーワード（企業キーワードと定義）を用い、業績要因文の学習データの自動生成する手法について述べる。企業キーワードの抽出については文献[6]を、拡張手がかり表現については、文献[4]を参照されたい。

- Step 1 : 企業の決算短信から既存手法[4]を用いて業績要因文を抽出する。
- Step 2 : 抽出した業績要因文に対し、企業キーワードを含みかつ拡張手がかり表現を含む文を抽出し、学習データの正例とする。
- Step 3 : 企業の決算短信から、企業キーワードと手がかり表現、どちらも含まない文を抽出する。
- Step 4 : Step 3 で抽出した文のうち文字数が一定以上の文を学習データの負例とする。

上記の処理を行うことにより、業績要因文の学習データを生成した。学習データは正例 12,2447 文、負例 12,2447 文の合計 244,894 文が生成された。

3.3. 業績結果の学習データの自動生成

業績結果の学習データの生成手法[5]を以下に示す。ランダムに選んだ、000 社の決算短信から以下の条件に合致する文をそれぞれ正例、負例とする。

・正例

「売上」「億円となりました」のどちらも含まれている文、例えば、「当社の当第3 四半期累計売上高は、主に前年同期比出荷ビットの増加により、32.2%増の4,222 億円となりました。」や「HE&S 分野の売上高は、液晶テレビの販売台数が減少しましたが、主に為替の好影響により、前年同期比 11.8%増加し、2,638 億円となりました。」である。

・負例

文中に算用数字、漢数字、共に含まない文、例えば「品質管理及びコンプライアンスに関する教育の強化につきましても継続的に推進しております。」や「以下、前年同期比については、当該変更を反映した前年同期の数値を用いております。」である。

以上の条件により業績結果文の学習データを生成する。学習データは正例 13,158 文、負例 339,198 文の合計 352,356 文が生成された。

4. 業績要因・業績結果の抽出

本手法の概要を以下に示す。

- Step 1 : 決算短信から文を抽出する。
- Step 2 : 抽出された文から既存手法[1]により原因・結果表現を抽出する。
- Step 3 : 抽出された原因表現を業績要因文の学習データによって構築された深層学習モデルにより、業績要因の判定を行う。
- Step 4 : 抽出された結果表現を業績結果文の学習

データによって構築された深層学習モデルにより、業績結果の判定を行う。

- Step 5 : 原因表現が業績要因と判定され、かつ、結果表現が業績結果であると判定されたのみを業績要因・業績結果として抽出する。

業績要因・業績結果の抽出手法の概要を図 1 に示す。

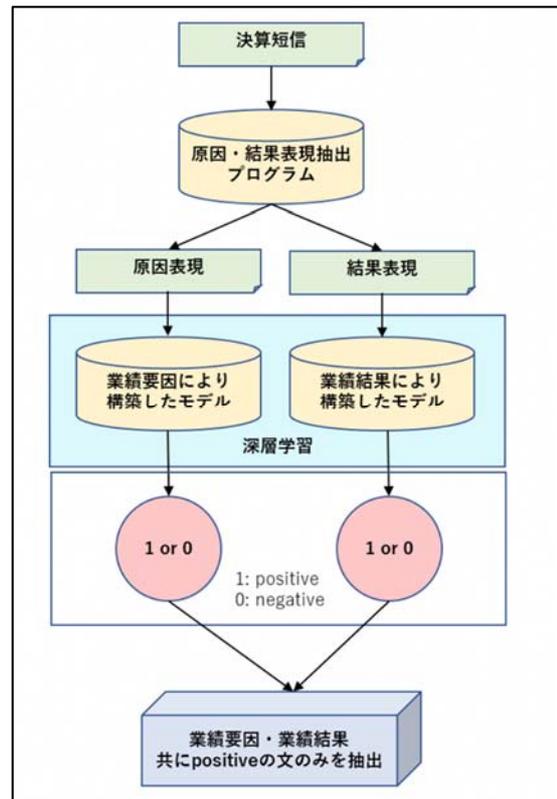


図 1 業績要因文・業績結果文の抽出の概要

4.1. 業績要因・業績結果の判定

本手法では、業績要因、業績結果の判定を深層学習モデルにより行った。深層学習モデルには多層パーセプトロンを採用した。学習データから文献[4]の手法により素性を抽出し、深層学習のモデルの入力層のノード数は学習データから抽出された素性の数と同じとした。中間層のノード数は、ノード数 1,000 の隠れ層が 3 層、ノード数 500 の隠れ層が 3 層、ノード数 200 の隠れ層が 3 層、ノード数 100 の隠れ層が 3 層の計 12 層とする。出力層はノード数 1 とし、エポック数は 50 として学習を行った。

本手法により業績要因・業績結果として抽出された因果関係の例を表 2 に示す。

表 2 業績要因・業績結果の因果関係の例

企業名	
業績要因	業績結果
明治海運	
消費増税後の駆け込み需要の反動減からの回復が当初の予想よりも遅れていることや、一部の季節商品の販売不振が続く	日曜雑貨事業の売上高が17億7千6百万円減少した
昭和電工	
リチウムイオン電池材料はスマートフォン向けに加え車載向けの出荷が増加し増収となりましたが、昭光通商株式会社は減収となりました	当セグメントの売上高は699億66百万円となりましたが、営業利益は主にリチウムイオン電池材料の数量増により10億46百万円となりました
コマツ	
【産業機械・車両他】産業機械・車両他部門では、産業機械事業およびフォークリフト事業が堅調	売上高は1,478億円となり、当部門のセグメント利益は139億円、売上高セグメント利益率は9.4%となりました

5. 評価

本手法により抽出された業績要因・業績結果の因果関係の評価は、上場企業2663社の決算短信を対象にして行った。

比較手法とし、深層学習で判定された業績原因に対し、企業キーワードでフィルタリングをかけての判定、結果表現に対し、「円」が含まれている場合を業績結果として判定を行った場合を比較した。また、ベースラインとして、本手法による業績要因・業績結果の判定を行う前（すなわち、既存研究[1]による抽出のみ）の場合の結果を評価した。

評価用のデータは上場企業2663社の決算短信から各企業の原因・結果表現1組ずつ抽出し、合計2663の評価セットにおいて、人手にて業績要因・業績結果を判定し、正解データを作成した。それぞれの手法での精度、再現率を表3に示す。

表 3 業績要因・業績結果判定の精度・再現率

手法 (業績要因 / 業績結果)	精度 (%)	再現率 (%)
ベースライン	3.81	100
深層学習モデル / 深層学習モデル	83.33	38.46
深層学習モデル / 「円」で判定	86.04	71.15
深層学習モデル + 企業キーワードでフィルタリング / 深層学習モデル	85.71	34.62
深層学習モデル + 企業キーワードでフィルタリング / 「円」で判定	91.55	62.5

6. 考察

深層学習モデルにより判定した結果、既存手法[1]と比べ、はるかに精度が上がった。最も精度が高かったものは、業績要因を深層学習モデルにより判定後、企業キーワードでフィルタリングをかけ、業績結果は「円」で判定をした場合であった。しかし、企業キーワードでフィルタリングをかけないものにと比べるとやや再現率が落ちてしまった。また、企業キーワードで絞り込みをかけてしまうと新規事業などの現状の企業キーワードにない単語が出てきてしまう場合に対応できない。そのため、多層パーセプトロン以外の手法で、文中の出現単語の前後関係を考慮するような時系列データを処理することが可能なRecurrent Neural Networksの一種であるLSTM(Long Short Term Memory)ネットワークを用い精度の向上を試みた。しかし、精度が最大で84.85%、再現率が32.69%と落ち込む結果となってしまった。これは素性の選択やモデルの構築が決算短信の文と合っていない可能性が考えられる。よって様々な素性での学習やモデルの構築をし、精度、再現率の向上を図る予定である。

本研究では業績要因・業績結果を決算短信から抽出したが、業績要因・業績要因である原因・結果表現や、数は少ないが業績結果・業績要因である因果関係も存在し、そのような情報も投資判断にとって有用であると考え。今後は、業績要因・業績要因である原因・結果表現や、業績結果・業績要因である原因・結果表現の抽出も行う予定である。

7. まとめ

本稿では、決算短信の原因・結果表現から業績要因・業績結果を抽出する手法を提案した。具体的には、業績要因の判定用深層学習モデルと業績結果の判定用深層学習モデルをそれぞれ作成し、両モデルが業績要因・業績結果と判定された原因・結果表現のみを業績要因・業績結果の因果関係であると判別した。評価の結果、精度は83.33%、再現率は71.15%と、高い精度で抽出することができた。

参考文献

- [1] 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.
- [2] 坂地泰紀, 増山繁: “新聞記事からの因果関係を含む文の抽出手法”, 電子情報通信学会論文誌 D, vol. J94-D, No. 8, pp.1496-1506, (2011)
- [3] 庵功雄: “新しい日本語学入門(第 2 版)”, スリーエーネットワーク, (2012)
- [4] 酒井浩之, 松下和暉, “決算短信からの業績要因文の抽出”, 第 11 回テキストアナリティクス・シンポジウム, pp.87-91, 2017.
- [5] 村野壮人, 酒井浩之, 坂地泰紀, 江口潤一, “決算短信から抽出した業績要因文の事業セグメントに基づく分類と業績文の抽出”, 第 19 回金融情報学研究会, pp.59-64, 2017.
- [6] 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.
- [7] 室野莉沙, 酒井浩之, 坂地泰紀, ベネット ジェイソン, “決算短信から抽出した原因・結果表現の意外性の判定”, 第 11 回テキストアナリティクス・シンポジウム, pp.87-91, 2017.
- [8] Hiroki Sakaji, Risa Muro, Hiroyuki Sakai, Jason Bennett, Kiyoshi Izumi, “Discovery of Rare Causal Knowledge from Financial Statement Summaries”, IEEE Symposium on Computational Intelligence for Financial Engineering & Economics (IEEE CIFER'17), Hawaii, November, 2017.

為替情報の幾何的特徴を用いた売買アルゴリズムの検討

Examination of trading algorithm applying geometry characteristics for foreign exchange data

河合 継¹, 新田 翔^{1,2}, 山口 航^{1,3}, 木村 祐輔¹, 西山 昇⁴

Kei Kawai¹, Sho Nitta^{1,2}, Wataru Yamaguchi^{1,3}, Yusuke Kimura¹, and Noboru Nishiyama⁴

¹クリスタルメソッド株式会社

¹ Crystal method co.ltd

²東京理科大学工学研究科経営工学専攻

² Department of Management Science, Graduate School of Engineering,
Tokyo University of Science

³東京工業大学情報理工学院情報工学系

³ Department of Computer Science, School of Computing, Tokyo Institute of Technology

⁴千葉商科大学会計大学院 客員教授

⁴ MBA Program, Graduate School of Accounting & Finance, Chiba University of Commerce

Abstract: In this paper, we examined a new method to predict fluctuation of foreign exchange rate. We input information extracted from historical data into PointNet++, which is proposed by C.R.Qi et al.[3] and predicted US Dollar to Yen Exchange rate 5 minutes later. The results implied that although there was tendency of overfitting, our method might capture a part of some structured factors of foreign exchange fluctuation. It is suggested that various range of approach related to machine learning could be useful for financial problems.

1. はじめに

外国為替取引は人々の関心を集め続けている。2015年のチャイナショック時には、瞬時に6円以上の円高が進行し、話題となった。為替取引が行われる理由は様々であるが、2018年時点で個人投資家でも25倍のレバレッジを利用可能、ショートポジションを取る際のハードルが株式取引よりも相対的に低い、などといった特徴から外国為替取引では短期取引を志向する投機的な行動が多くみられると言われている。そうした市場環境の中で、取っているポジションのリスクを定量的に把握したり、売買タイミングを判定したりするようなアルゴリズムへの高い需要が存在すると予想される。

近年、機械学習を活用することで、金融商品の取引において高いリターンを達成しようとする試みが活発に行われている。例えば石原[4]は多層ニューラルネットワークと遺伝的アルゴリズムを用いたトレーディング手法によって、TOPIXを上回る運用成績を達成したことを報告している。また、今村ら

[5]では、金融実務に置いて伝統的に用いられているペア・トレードと呼ばれる手法と、LSTM (Long Short Term Memory) を組み合わせることで、良好な結果を得たと報告している。

これらは、株式市場でのAIの応用例であるが、本稿では、為替取引における機械学習的なアプローチを検討する。具体的には、三次元点群形式のデータの幾何的な構造を捉えることに長けた PointNet++ と呼ばれる学習器を用いて、為替取引における売買タイミングを予測する手法の検討を行う。今回、為替取引にこれを応用する背景には以下のような状況がある。

まず、梅田ら[6]が指摘するように、従来使われている統計的な解析手法では、データの分布を仮定する必要があった。しかし、ビッグデータの収集および処理が可能になりつつある近年、単純な分布を仮定するだけでは必ずしも説明できない事象も多く知られるようになってきた。これに対し、データ特有の特徴を利用した個別の解析手法を構築したり、R.Fujimaki et al [1]のように、出来るだけ情報を保存

したまま複数の分布を組み合わせようとする工夫がなされてきた。しかし、それらの場合でもデータの詳細な情報が事前に必要になったり、データが局所的に従っている分布についての仮定が必要になったりと、問題は完全には解決されなかった。

そこで、梅田ら[6]のように、「データの形」を把握することで、従来の統計的データ解析手法が取りこぼしていた情報を汲みとろうとしてきた背景がある。

このような状況を踏まえ、本稿では三次元の点群形式データの幾何的な特徴を処理することに長けた PointNet++ を学習器として採用し、為替の変動予測を行った。さらに、その変動予測に基づく売買アルゴリズムのパフォーマンス測定を行った。次節以降、この PointNet++ を用いて行った実験について説明する。

2. PointNet++

C.R.Qi et al [2]は、物体を描画した点群を三次元ボクセルや画像に変換することなく、直接処理することができる PointNet と呼ばれるアーキテクチャを提案した。これに対し、C.R.Qi et al [3]によって提案された PointNet++ は、PointNet のネットワークに階層的な構造を導入することで、インプット情報の局所的な構造を捉える精度を向上させたものである。

2.1. データの取得

FXDD (URL : <https://secure.fxdd.com/us/jp/forex-resources/forex-trading-tools/metatrader-1-minute-data/>) より、2005年1月から2018年7月までのドル円の1分足の為替データを入手した。なお、入手したデータは5分足に直してから使用した。

2.2. 入力値

ここでは、学習器に入力したデータの説明を行う。まず、金融実務においてよく参照される指標を15個リストアップした (表1)。これらの指標に対し、主成分分析(PCA)と t-SNE を用いて次元削減を行った。次元削減後の各データの次元は三とし、これを PointNet++ の入力とした。

表1 : 入力データ作成に用いた指標

指標	タイムピリオド
Absolute Price Oscillator	12, 26
Aroon Down	14
Aroon Up	14
Average True Range	12
Chande Momentum Oscillator	14
Rate Of Change	10
Minus Directional Movement	14
Midpoint	14
Plus Directional Movement	14
Relative Strength Index	12
Slow %D	5, 3
Slow %K	5, 3
Simple Moving Average	24
Ultimate Oscillator	7, 14, 28
William's %R	14

2.3. 主成分分析(PCA)と t-SNE(t-distributed Stochastic Neighbor Embedding)

両手法は、多次元データを次元圧縮するときに利用される。PCA は線形変換系手法の代表的な圧縮方法であるが、多次元データに多変量正規分布が仮定されている。

一方 t-SNE は、多変量正規分布が仮定されていないデータであっても次元圧縮に利用できる手法とされており、クラスターを可視化する際に有効な手法とされている。

3. 実験

まず、教師データに関する説明を行う。連続する512時点分の三次元データを間隔256で移動させて、学習器にインプットする。正解ラベルの作成は、5分後の価格変動に応じて行った。ラベルの設定は、表2の通りである。

表2 : ラベルの設定

変動	ラベル
n pips 以上上昇	UP
n pips 以上下落	DOWN
その他	STAY

n=1,5

また、全データの4分の3を学習用データに、4分の1をテスト用データに割り当てた。

以上の条件のもとで学習を行った。エポック数は251、バッチサイズは16とし、最適化手法は Adam (Adaptive Moment Estimation)を用いた。

また、学習後の PointNet++を用いた売買アルゴリズムのシミュレーションを行った。対象となる区間は学習に用いていない期間(2015-03-12 18:05:00 ~ 2018-07-28 00:30:00)で、入力に対する出力が「UP」

である場合には買いを、「DOWN」である場合には売りを入れ、「STAY」である場合には何もしないという条件を設定した。なお、売買を行った場合は、次のステップで反対売買するものとする。また、スプレッドや取引手数料は考慮に入れていない。

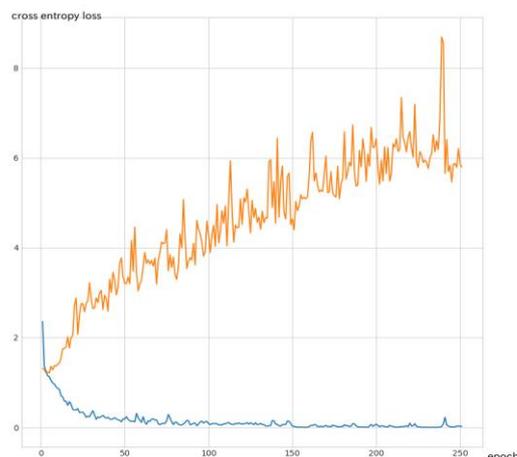


図 1 -b: t-SNE/ 1 pips

3. 結果

3.1. 学習の結果

学習の結果、loss は図 1、accuracy は図 2 のように推移した。

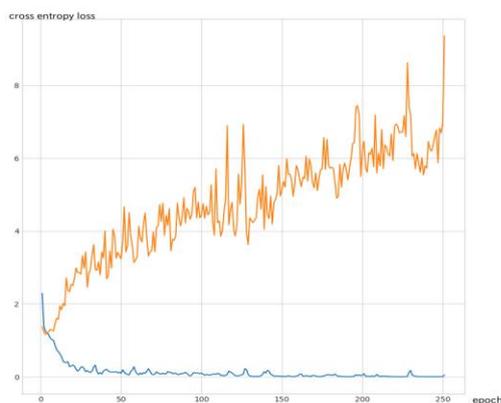


図 1 -a: PCA/ 1 pips

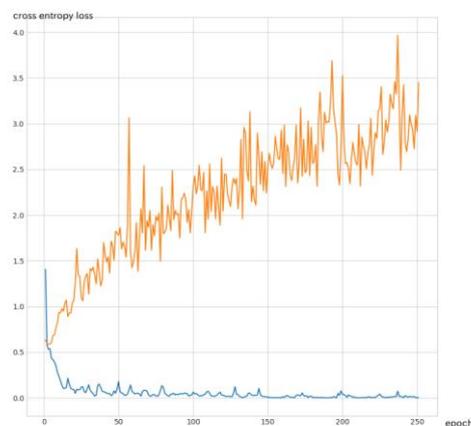


図 1 -c: PCA/ 5 pips

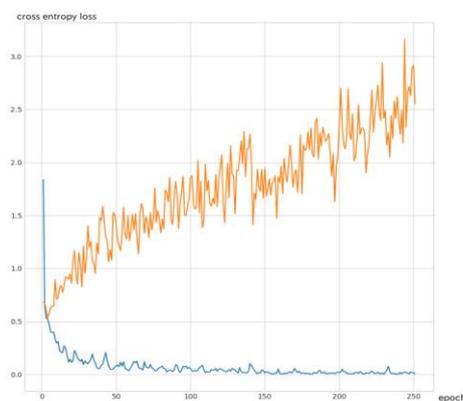


図 1 -d: t-SNE/ 5 pips

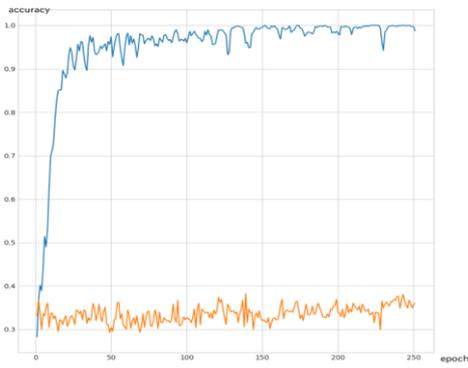


図 2 -a: PCA/ 1 pips



図 2 -d: t-SNE/ 5 pips

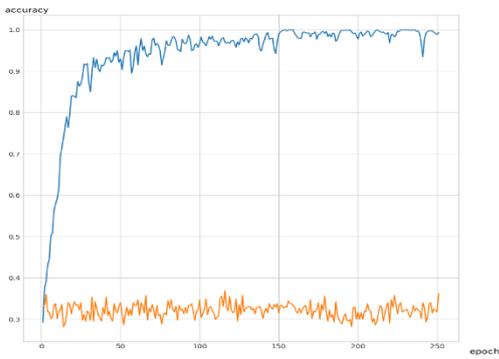


図 2 -b: t-SNE/ 1 pips



図 2 -c: PCA/ 5 pips

3.2. 売買シミュレーションの結果

学習済みの PointNet++を用いて売買のシミュレーションを行った結果は図3の通りである。

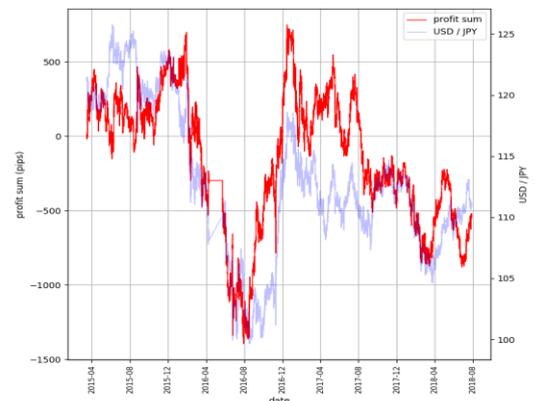


図 3 -a: PCA/ 1 pips

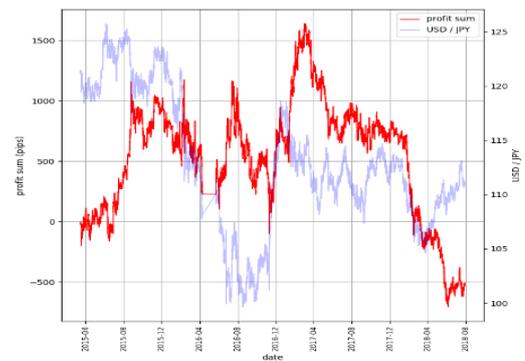


図 3 -b: t-SNE/ 1 pips

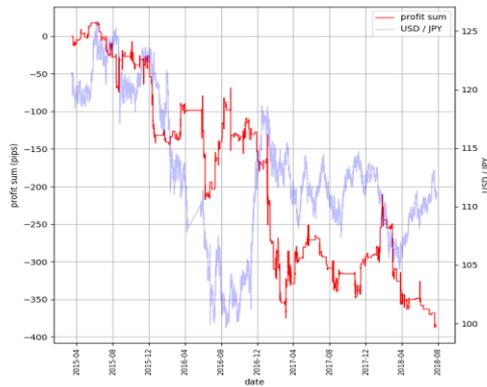


図 3 - c : PCA / 5 pips

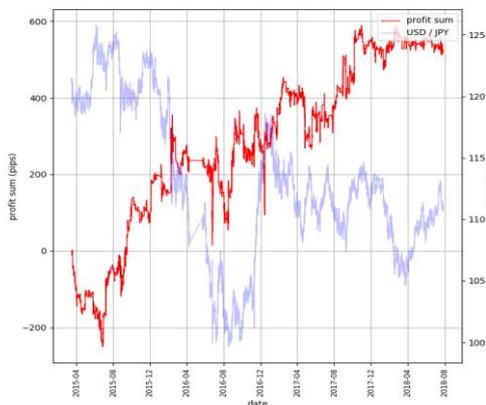


図 3 - d: t-SNE / 5 pips

4. 考察

4つの売買シミュレーションの中で唯一、t-SNE/5 pips のものだけは最終的に利益を出している (図 3-d)。同じ5 pips でも、t-SNE が順調に利益を上げていっている反面、PCA では徐々に負けが増えている (図 3-c, 図 3-d)。まず、この理由を考えてみたい。

本実験では、PointNet++を用いることによって、できるだけデータが持つ構造をそのまま扱おうという意図があった。一方、PCA には非線形な構造を捉えきれないというデメリットがあり、データの次元を削減して三次元とした時点で既に、本来存在していた構造が失われていた可能性がある。これに対し、t-SNE による次元削減では、データの構造に関する情報を失うことがなかったと考えれば、この結果にも説明がつく。もちろんこの結果が偶然にすぎないという可能性も排除しきれない。

図 1 は学習器が過学習に陥っていることを示唆している。学習が進むごとに訓練データに対しては loss の減少が見られるが、未知データに対しては loss の減少が見られない。これは、学習器が、為替変動の本質的要因を完全に捉えきれていない可能性を意味する。

accuracy に対しても同様のことが言える。訓練データでは精度の向上が見られるのに比べ、1 pips の未知データでは3分の1程度の正答率に留まっている。5 pips の未知データでは高い正答率が達成されているが、これは「STAY」に分類されたデータ数が圧倒的に多いため、大多数の局面で「STAY」と予想しておけば正答率自体は高い水準をキープ出来たということであろう。

過学習に陥った原因であるが、為替の短期的な変動が、本質的にランダムである可能性が挙げられる。為替レートがランダムに変動するのであれば、ヒストリカルデータから未来の変動を予測するという試み自体が無理となる。あるいは、今回分析したデータに含まれない、金利等の経済指標の影響で価格変動している可能性もある。

5. 終わりに

本研究では、機械学習の分野で発展してきた、情報を損なわずにデータを扱う手法が金融データに対しても適用できる可能性が示唆された。

t-SNE と PointNet++を組み合わせた手法の中の一つのパターンでは、未知データに対する売買シミュレーションにおいて最終的に利益を確保することが示された。

一方で課題は多い。まず、過学習をどのように克服するかがある。本実験では、学習が進むに連れて、未知データに関する loss が大きくなるという、汎用的な特徴でなく、より局部の特徴のみをとってしまっている過学習の傾向が生じた。

この原因がネットワークにあるのか、インプット情報にあるのかははっきり特定できていない。

そして、今回は経済のファンダメンタルな情報を考慮できなかったことも大きい。通貨の価値は、その国の経済状況や政治リスクに影響を受ける。

今回は超短期取引でのシミュレーションとはいえ、それらの情報を検証対象にできなかったことは、市場変動の説明要因を損なっていた可能性がある。

次回以降は、これらの課題点を念頭に置き、予測の精度向上を目指したい。

参考文献

- [1] R.Fujimaki, S.Morinaga: Factorized Asymptotic Bayesian Inference for Mixture Modeling. Proceedings of the fifteenth international conference on Artificial Intelligence and Statistics(AISTATS),2012.
- [2] C.R.Qi, H.Su, K.Mo, and L.J.Guibas: Pointnet: Deep learning on point sets for 3d classification and segmentation, IEEE Conference on Computer Vision and Pattern Recognition,2017
- [3] C.R.Qi, H.Su, and L.J.Guibas: Pointnet: PointNet++: Deep Hierarchical Feature Learning on Point Sets in Metric Space, Neural Information Processing Systems,2017
- [4] 石原龍太: 多層ニューラルネットワークと GA を用いた TOPIX 運用 AI, 第19回 人工知能学会 金融情報学研究会(SIG-FIN), 2017
- [5] 今村光良, 中川慧, 吉田健一: 機械学習を用いた共和分ペア・トレード戦略, 第19回 人工知能学会 金融情報学研究会(SIG-FIN), 2017
- [6] 梅田裕平, 金児純司, 菊地英幸: トポロジカルデータアナリシスと時系列データ解析への応用, FUJITSU, Vol. 69, No. 4, pp. 97-103, 2018

金融時系列のための深層 t 過程回帰モデルDeep t -Process Regression Model for Financial Time-Series Analysis中川 慧^{1*} 角屋 貴則² 内山 祐介^{2,3}
Kei Nakagawa¹ Takanori Kadoya² Yusuke Uchiyama^{2,3}¹ 野村アセットマネジメント株式会社¹ Nomura Asset Management Co., Ltd.² 株式会社 MAZIN² MAZIN, Inc.³ 筑波大学 システム情報系³ University of Tsukuba Faculty of Engineering, Information and Systems

Abstract: 深層学習をガウス過程で構築する手法が近年提案された。これは深層学習に対するカーネル関数をガウス過程の共分散関数として使用し、深層学習モデルの完全なベイズ推論を行う。これにより通常の深層学習にはない、予測の不確実性が考慮できる等のメリットが得られる。我々は、この手法を一般に裾の厚いといわれる金融データへ適用することを目的に、ガウス過程から t 過程への拡張を行う。実証分析の結果、金融時系列においてガウス過程よりも良好な結果が得られた。

1 はじめに

ガウス過程とは、確率変数の集まりであって、どの有限個の確率変数をとっても、その結合分布がガウス分布になっているようなものをいう。そして、ガウス分布が期待値と共分散行列で特定されるのと同様に、ガウス過程は期待値関数と共分散(カーネル)関数という、2つの関数によって特定される。カーネル関数について、[4]によると、単一隠れ層でユニット数が無限のニューラルネットワークをガウス過程のカーネル関数として表現できることが知られている。また、隠れ層が多層の場合のニューラルネットワーク(深層学習)に対応するカーネル関数も[1]によって導出された。以上を用いて、[2]は多層のニューラルネットワークに対応するカーネル関数を用いて、ガウス過程としての深層学習を構築した。深層学習をガウス過程として扱うメリットとして、大きく次の2点が挙げられる。1つ目が予測の不確かさを考慮することができる点である。もう1つが、カーネル関数を使うことで、隠れ層に無限個のユニットがある深層学習を考えていることになるため、表現力が高く、精度向上が期待できる。実際に、[2]ではMNISTやCIFAR10といった画像データを用いて上記のメリットを確認している。以上のことから、深層学習をガウス過程として表現することは有効であると言える。一方で、画像データではなく金融市場のデー

タに着目すると、金融資産の価格変動は一般にガウス分布ではテール部分を当てはめることができないことが、[3]以来広く知られている。そこで我々は、[2]の深層ガウス過程を、一般に裾が厚いといわれる金融市場データへの適用を目的に、深層 t 過程へと拡張する。 t 過程は、ガウス過程より裾の厚いデータを表現でき、ガウス過程の代替として注目を集めている[7]。 t 過程により、外れ値に左右されにくい推定(回帰)が可能になる。

本稿の構成は次の通りである。次章においてまず基本となるガウス過程回帰モデルを簡単に述べる。次に、提案手法を構成する、 t 過程回帰モデルおよび深層学習カーネル関数を定義する。そして、 t 過程回帰モデルの導出を行い、実際の金融市場のデータを用いた実証分析によって有効性を評価する。最後に結論を延べる。

2 ガウス過程回帰モデル

確率過程 \mathbf{f}_{GP} が、入力ベクトルから成る任意の有限集合 $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_n]^T \subset \mathcal{R}^d$ に対して、関数値のベクトル $\mathbf{f}_{GP} = [f_{GP}(\mathbf{x}_1), \dots, f_{GP}(\mathbf{x}_n)]^T$ の分布がガウス分布であるとき、ガウス過程という。 \mathbf{f}_{GP} の分布は、ガウス分布であるので、その期待値を指定する平均関数 $\boldsymbol{\mu} = [\mu_1(\mathbf{x}_1), \dots, \mu_n(\mathbf{x}_n)]$ および、共分散(カーネル)関数 $k(\mathbf{x}_n, \mathbf{x}_m)$ の値 K_{nm} を要素とする共分散行列 \mathbf{K} を指定することによって完全に特定できる。これを、 $\mathbf{f}_{GP} \sim N(\boldsymbol{\mu}(\mathbf{x}), \mathbf{K}(\mathbf{x}, \mathbf{x}_0))$ と書く。直感的にはガウス

*連絡先: 野村アセットマネジメント株式会社
〒103-0027 東京都中央区日本橋1丁目12-1
E-mail: kei.nak.0315@gmail.com

過程は入力 \mathbf{X} が似ていれば、出力 \mathbf{f}_{GP} も似ており、似ていることの定義はカーネル関数によって与えられる。

ここで、 n 個の学習データ (\mathbf{x}_i, y_i) , $\mathbf{x}_i \in \mathcal{R}^d, y_i \in \mathcal{R}$ が与えられたとき、 $y_i = f_{GP}(\mathbf{x}_i) + \varepsilon_i, \varepsilon_i \sim N(0, \sigma^2)$ という回帰問題を考える。 $\mathbf{f}_{GP} = [f_{GP}(\mathbf{x}_1), \dots, f_{GP}(\mathbf{x}_n)]^T$ と定義し、 $\mathbf{f}_{GP} \sim N(\boldsymbol{\mu}(\mathbf{x}), \mathbf{K}(\mathbf{x}, \mathbf{x}_0))$ に従うとする。 \mathbf{X} が与えられた後の \mathbf{y} の分布は、 \mathbf{f}_{GP} と ε_i の2つの独立なガウス分布の畳み込みなので、再びガウス過程となり、 $N(\boldsymbol{\mu}(\mathbf{x}), \mathbf{K}(\mathbf{x}, \mathbf{x}_0) + \sigma^2 \mathbf{I})$ となる。次に、新たな m 個の未観測のデータ $\mathbf{Z} = [\mathbf{z}_1, \dots, \mathbf{z}_m]^T$ が与えられたときの、予測値 $\mathbf{f}_{GP}^* = [f_{GP}(\mathbf{z}_1), \dots, f_{GP}(\mathbf{z}_m)]^T$ を考える。観測値 \mathbf{y} と予測値 \mathbf{f}_{GP}^* の同時分布は、 \mathbf{Z} と \mathbf{X} の間のカーネルを考えることで、またガウス分布になるので、

$$\begin{pmatrix} \mathbf{y} \\ \mathbf{f}_{GP}^* \end{pmatrix} \sim N \left(\begin{bmatrix} \boldsymbol{\mu}(\mathbf{X}) \\ \boldsymbol{\mu}(\mathbf{Z}) \end{bmatrix}, \begin{bmatrix} \mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma^2 \mathbf{I} & \mathbf{K}(\mathbf{Z}, \mathbf{X})^T \\ \mathbf{K}(\mathbf{Z}, \mathbf{X}) & \mathbf{K}(\mathbf{Z}, \mathbf{Z}) \end{bmatrix} \right) \quad (1)$$

と書ける。したがって、予測分布は条件付きガウス分布を考えることで、次のよう書ける。

$$p(\mathbf{f}_{GP}^* | \mathbf{X}, \mathbf{y}, \mathbf{Z}) \sim N(\hat{\boldsymbol{\mu}}, \hat{\boldsymbol{\Sigma}}) \quad (2)$$

ただし、

$$\begin{aligned} \hat{\boldsymbol{\mu}} &= \mathbf{K}(\mathbf{Z}, \mathbf{X})^T (\mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma^2 \mathbf{I})^{-1} (\mathbf{y} - \boldsymbol{\mu}(\mathbf{X})) \\ &\quad + \boldsymbol{\mu}(\mathbf{Z}) \\ \hat{\boldsymbol{\Sigma}} &= \mathbf{K}(\mathbf{Z}, \mathbf{Z}) \\ &\quad - \mathbf{K}(\mathbf{Z}, \mathbf{X})^T (\mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma^2 \mathbf{I})^{-1} \mathbf{K}(\mathbf{Z}, \mathbf{X}) \end{aligned} \quad (3)$$

である。ガウス過程回帰は線形回帰モデルを含んでおり、線形回帰の拡張となっている。線形回帰とは異なり、カーネル法を用いることでより柔軟な関数近似が可能となり、外挿に強いなどの利点がある。

3 t 過程回帰モデル

ガウス過程と同様に、確率過程 \mathbf{f}_{TP} が、入力の任意の有限集合 \mathbf{X} に対して、関数値のベクトル \mathbf{f}_{TP} の分布が多変量 t 分布であるとき、 t 過程という。 \mathbf{f}_{TP} の分布は、 t 分布であるので、自由度 $\nu \in \mathcal{R}^+ \setminus [0, 2]$ と平均関数 $\boldsymbol{\mu}$ および、共分散 (カーネル) 関数を要素とする共分散行列 \mathbf{K} を指定するによって完全に特定できる。これを、 $\mathbf{f}_{TP} \sim T(\nu, \boldsymbol{\mu}(\mathbf{x}), \mathbf{K}(\mathbf{x}, \mathbf{x}_0))$ と書く。ここで、 $T(\nu, \boldsymbol{\mu}, \mathbf{K})$ は多変量 t 分布であり、確率変数 $\mathbf{y} \in \mathcal{R}^n$

に対して、次の密度関数を持つ。

$$T(\nu, \boldsymbol{\mu}, \mathbf{K}) = \frac{\Gamma(\frac{\nu+n}{2})}{((\nu-2)\pi)^{\frac{n}{2}} \Gamma(\frac{\nu}{2})} (\det \mathbf{K})^{-\frac{1}{2}} \times \left(1 + \frac{(\mathbf{y} - \boldsymbol{\mu})^T \mathbf{K}^{-1} (\mathbf{y} - \boldsymbol{\mu})}{\nu - 2} \right)^{-\frac{\nu+n}{2}} \quad (5)$$

ただし、 $\Gamma(\cdot)$ はガンマ関数である。容易にわかるように¹、多変量 t 分布は $\nu \rightarrow \infty$ としたものがガウス分布となり、ガウス分布のある種の一般化となっている。

ここで、 n 個の学習データ (\mathbf{x}_i, y_i) , $\mathbf{x}_i \in \mathcal{R}^d, y_i \in \mathcal{R}$ が与えられたとき、 $y_i = f_{TP}(\mathbf{x}_i) + \varepsilon_i, \varepsilon_i \sim T(\nu, 0, \sigma^2)$ という回帰問題を考える。 $\mathbf{f}_{TP} = [f_{TP}(\mathbf{x}_1), \dots, f_{TP}(\mathbf{x}_n)]^T$ と定義し、 $\mathbf{f}_{TP} \sim T(\boldsymbol{\mu}(\mathbf{x}), \mathbf{K}(\mathbf{x}, \mathbf{x}_0))$ に従うとする。 \mathbf{X} が与えられた後の \mathbf{y} の分布は、 \mathbf{f}_{TP} と ε_i の2つの独立な t 分布の畳み込みなので、再び t 過程となり、 $T(\nu, \boldsymbol{\mu}(\mathbf{x}), \mathbf{K}(\mathbf{x}, \mathbf{x}_0) + \sigma \mathbf{I})$ となる。次に、新たな m 個の未観測のデータ $\mathbf{Z} = [\mathbf{z}_1, \dots, \mathbf{z}_m]^T$ が与えられたときの、予測値 \mathbf{f}_{TP}^* を考える。観測値 \mathbf{y} と予測値 \mathbf{f}_{TP}^* の同時分布は、 \mathbf{Z} と \mathbf{X} の間のカーネルを考えることで、また t 分布になるので、

$$\begin{pmatrix} \mathbf{y} \\ \mathbf{f}_{TP}^* \end{pmatrix} \sim T \left(\nu, \begin{bmatrix} \boldsymbol{\mu}(\mathbf{X}) \\ \boldsymbol{\mu}(\mathbf{Z}) \end{bmatrix}, \begin{bmatrix} \mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma^2 \mathbf{I} & \mathbf{K}(\mathbf{Z}, \mathbf{X})^T \\ \mathbf{K}(\mathbf{Z}, \mathbf{X}) & \mathbf{K}(\mathbf{Z}, \mathbf{Z}) \end{bmatrix} \right) \quad (6)$$

と書ける。したがって、予測分布は6章の条件付き t 分布を考えることで、次のよう書ける。

$$p(\mathbf{f}_{TP}^* | \mathbf{X}, \mathbf{y}, \mathbf{Z}) \sim T(\hat{\nu}, \hat{\boldsymbol{\mu}}, \hat{\boldsymbol{\Sigma}}) \quad (7)$$

ただし、

$$\begin{aligned} \hat{\nu} &= \nu + n, \\ \hat{\boldsymbol{\mu}} &= \mathbf{K}(\mathbf{Z}, \mathbf{X})^T (\mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma^2 \mathbf{I})^{-1} (\mathbf{y} - \boldsymbol{\mu}(\mathbf{X})) \\ &\quad + \boldsymbol{\mu}(\mathbf{Z}) \\ \hat{\boldsymbol{\Sigma}} &= \frac{\nu - \beta - 2}{\nu - n - 2} \times \\ &\quad [\mathbf{K}(\mathbf{Z}, \mathbf{Z}) \\ &\quad - \mathbf{K}(\mathbf{Z}, \mathbf{X})^T (\mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma^2 \mathbf{I})^{-1} \mathbf{K}(\mathbf{Z}, \mathbf{X})] \end{aligned} \quad (8)$$

$$\quad (9)$$

$$\quad (10)$$

3.1 パラメータ推定

GPRと同様に、カーネル内のハイパーパラメータと自由度を含むすべてのパラメータは、次の尤度関数を用いた最尤法によって推定することができる。入力 \mathbf{X} 、

¹カーネル部分 $(1 + \frac{(\mathbf{y} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{y} - \boldsymbol{\mu})}{\nu - 2})^{-\frac{\nu+n}{2}}$ に着目すると、指数関数の定義 $e^x = \lim_{n \rightarrow \infty} (1 + \frac{x}{n})^n$ から、 $e^{-\frac{(\mathbf{y} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{y} - \boldsymbol{\mu})}{2}}$ となり、ガウス分布に収束することがわかる。

ハイパーパラメータ θ としたとき尤度関数は次のように書ける。

$$\begin{aligned} L &= -\log p(\mathbf{y}|\mathbf{X}, \boldsymbol{\theta}, v) \\ &= \frac{\nu+n}{2} \log \left(1 + \frac{\delta}{\nu-2} \right) + \frac{1}{2} \log \det \mathbf{K}_\theta \\ &\quad + \frac{n}{2} \log ((\nu-2)\pi) \\ &\quad + \log \Gamma \left(\frac{\nu}{2} \right) - \log \Gamma \left(\frac{\nu+n}{2} \right) \end{aligned} \quad (11)$$

ここで $\delta = (\mathbf{y}-\boldsymbol{\mu})^T \mathbf{K}_\theta^{-1} (\mathbf{y}-\boldsymbol{\mu})$ および $\mathbf{K}_\theta = K(\mathbf{X}, \mathbf{X})$ である。

4 深層学習カーネル

[2] は、 $\sigma_b^2, \sigma_w^2 \in \mathcal{R}$ を与えたとき、次の式がカーネル関数として、無限のユニットを持つ全結合の深層学習と同様の表現力を持つことを示した。

$$\begin{aligned} K^l(\mathbf{x}, \mathbf{x}') &= \sigma_b^2 \\ &\quad + \sigma_w^2 F_\phi(K^{l-1}(\mathbf{x}, \mathbf{x}), K^{l-1}(\mathbf{x}, \mathbf{x}'), K^{l-1}(\mathbf{x}', \mathbf{x}')) \end{aligned} \quad (12)$$

ここで、 F は l 層目の非線形変換 ϕ から決定的に求められる。具体的に ReLU を非線形関数として選んだ場合の再帰式は次のように書ける。この深層学習カーネルを計算し、あとは t 過程回帰の予測式にこれを代入し計算すれば、深層 t 過程回帰による予測が得られる。

$$\begin{aligned} K^l(\mathbf{x}, \mathbf{x}') &= \sigma_b^2 + \frac{\sigma_w^2}{2\pi} \sqrt{K^{l-1}(\mathbf{x}, \mathbf{x})K^{l-1}(\mathbf{x}', \mathbf{x}')} \\ &\quad \times \sin \theta^{l-1} + (\pi - \theta^{l-1}) \cos \theta^{l-1}, \end{aligned} \quad (13)$$

ただし、

$$\theta^l = \cos^{-1} \left(\frac{K^l(\mathbf{x}, \mathbf{x}')}{\sqrt{K^l(\mathbf{x}, \mathbf{x})K^l(\mathbf{x}', \mathbf{x}')}} \right) \quad (14)$$

5 実証分析

ここでは、提案手法である深層 t 過程回帰モデルの有効性を確認するために、実際の金融市場のデータを用いた実証分析を行う。使用するデータとして、SP500、TOPIX、DAX 指数の月次データを使用する。各指数の配当利回り、PBR、PER、ROE、12-1 か月モメンタムを説明変数とし、翌月のリターンを非説明変数とする。データは 2018/6 末から直近 12 年分 (144 サンプル) を使用し、うち推定に 7 割 (100 サンプル) の、テストに 3 割のデータを使用する。全期間における各指数の統計量は表 5 の通りである。よく知られているように各指数ともに正規性を満たさないため、本研究の

	TPX	SPX	DAX
年率リターン [%]	2.37	7.38	8.15
年率リスク [%]	18.02	14.24	18.32
歪度	-0.47	-0.82	-0.56
尖度	5.22	6.20	5.69
Jarque-Beta 統計量	12.94	41.75	23.67
p-値 [%]	0.1550	0.0000	0.0007

表 1: 各指数における統計量

ような裾の厚い分布を当てはめる余地は十分にあると言える。

具体的な推定手順は下記の通りである。

1. 深層学習カーネルのハイパーパラメータ σ_w^2 と σ_b^2 の初期値を 0.1 とする
2. 観測ノイズのパラメータ σ を 0.005 で与える
3. カーネルをフィッティングし、テストデータを予測
4. ガウス過程、 t 過程をそれぞれ最尤推定する

分析にあたっては、先行研究にて提案されている深層学習カーネルを用いたガウス過程 (GP) と、本研究の提案手法である深層学習カーネルを用いた t 過程 (TP) の予測誤差を RMSE と MAE それぞれで評価する。結果のサマリーが表 5 である。上段が Total、中段が予測誤差が上位 50%、下段が予測誤差が下位 50% の RMSE と MAE を記載している。また、太字は GP または TP うち精度の良い方を示している。まずは、表 5 の上段より、全ての指数において、回帰モデルとして TP は GP よりも RMSE、MAE の両方で良いことが確認できる。次に、表 5 の中段、下段は予測誤差が大きいケースと小さいケースで誤差にどの程度の差があるかを評価したものである。GP、TP とともに予測誤差が大きい場合、すなわち予測の不確実性が高い場合には、予測精度が悪くなっていることがわかる。これは、[2] と整合的な結果であり、通常の深層学習を含めた識別モデルの場合には得られない分布を仮定することによって得られる情報である。TP は予測誤差の大小に関わらず、GP よりも精度が改善している。以上から、提案手法は金融市場において回帰モデルとして [2] のモデルより有効であると言える。

6 条件付き多変量 t 分布

[7] において、多変量 t 分布の条件付き分布の導出が行われているが、カーネル部分のみであり、自由度のパラメータに不完全な部分が残る。そこで、本稿ではカーネル部分以外も含めた完全な多変量 t 分布の条件付き分布の導出を行う。

指数	TPX		SPX		DAX	
	GP	TP	GP	TP	GP	TP
Total						
RMSE	0.3511	0.2158	1.0357	0.5076	0.2934	0.1134
MAE	0.2914	0.1622	0.8910	0.4282	0.2489	0.0808

予測誤差 (大)	GP	TP	GP	TP	GP	TP
RMSE	0.3561	0.2623	1.3646	0.6856	0.3285	0.1390
MAE	0.2937	0.2079	1.3431	0.6674	0.2759	0.1014

予測誤差 (小)	GP	TP	GP	TP	GP	TP
RMSE	0.3458	0.1524	0.5650	0.2343	0.2553	0.0800
MAE	0.2892	0.1142	0.4594	0.1999	0.2231	0.0602

表 2: 各指数における RMSE と MAE のサマリー: 上段が Total、中段が予測誤差が上位 50%、下段が予測誤差が下位 50%。太字は GP または TP のうち精度の良い方を示している。

6.1 ブロック行列に関する補題

まずは証明にあたり必要な補題を証明なしに準備する。これらの証明については、例えば [6] 中にある。ブロック行列の逆行列および行列式の補題を以下のように準備する。

$$\Sigma^{-1} = \begin{bmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{12}^T & \Sigma_{22} \end{bmatrix}^{-1} = \begin{bmatrix} \Lambda_{11} & \Lambda_{12} \\ \Lambda_{12}^T & \Lambda_{22} \end{bmatrix} = \Lambda \quad (15)$$

ここで、

$$\Lambda_{11} = (\Sigma_{11} - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{12}^T)^{-1}, \quad (16)$$

$$\Lambda_{22} = (\Sigma_{22} - \Sigma_{12}^T\Sigma_{11}^{-1}\Sigma_{12})^{-1}, \quad (17)$$

$$\Lambda_{12} = \Lambda_{11}\Sigma_{12}(\Sigma_{22} - \Sigma_{12}^T\Lambda_{11}\Sigma_{12})^{-1} \quad (18)$$

であり、行列式については以下の関係が成り立つ。

$$\det |\Sigma| = \frac{\det |\Sigma_{22}|}{\det |\Lambda_{11}|} \quad (19)$$

6.2 多変量 t 分布の分割

ガウス過程の証明 [5] と同様に次元 n 、平均 μ 、共分散行列 Σ 、自由度 ν の多変量 t 分布 X を X_1, X_2 に分割する。そして、 X_2 が所与のもとでの X_1 の条件付き分布の導出を行う。 X_1, X_2 のそれぞれの次元は n_1, n_2 、平均ベクトル μ_1, μ_2 、共分散行列を $\Sigma_{11}, \Sigma_{12}, \Sigma_{22}$ 、自由度を ν_1, ν_2 とする。次元および自由度については、 $n_1 + n_2 = n$ と $\nu_1 + \nu_2 = \nu$ の関係が成立する。すなわち、

$$X = \begin{bmatrix} X_1 \\ X_2 \end{bmatrix}, \mu = \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix}, \Sigma = \begin{bmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{12}^T & \Sigma_{22} \end{bmatrix} \quad (20)$$

である。以上を用いて記号の簡便化のためマハラノビス距離を次のように定義する。

$$\Delta = (X - \mu)^T \Lambda (X - \mu) = \Delta_1^* + \Delta_2, \quad (21)$$

$$\Delta_1^* = (X_1 - \mu_{1|2})^T \Lambda_{11} (X_1 - \mu_{1|2}), \quad (22)$$

$$\mu_{1|2} = \mu_1 - \Lambda_{11}^{-1} \Lambda_{12} (X_2 - \mu_2), \quad (23)$$

$$\Delta_2 = (X_2 - \mu_2)^T \Lambda_{22} (X_2 - \mu_2) \quad (24)$$

さて、 X_2 が所与のもとでの X_1 の条件付き分布は、多変量 t 分布の定義から、

$$\begin{aligned} p(X_1|X_2) &= \frac{p(X_1, X_2)}{p(X_2)} \\ &= \frac{\Gamma(\frac{\nu+n}{2})(\det\Sigma)^{-\frac{1}{2}}}{((\nu-2)\pi)^{\frac{n}{2}}\Gamma(\frac{\nu}{2})} \left(1 + \frac{\Delta}{\nu-2}\right)^{-\frac{\nu+n}{2}} \\ &\quad \times \frac{((\nu-2)\pi)^{\frac{n_2}{2}}\Gamma(\frac{\nu}{2})}{\Gamma(\frac{\nu+n_2}{2})(\det\Sigma_{22})^{-\frac{1}{2}}} \left(1 + \frac{\Delta_2}{\nu-2}\right)^{\frac{\nu+n_2}{2}} \end{aligned} \quad (25)$$

と書ける。まずは $p(X_1, X_2)$ と $p(X_2)$ の規格化定数に着目すると、

$$= \frac{\Gamma(\frac{\nu+n}{2})(\det\Sigma)^{-\frac{1}{2}}}{((\nu-2)\pi)^{\frac{n}{2}}\Gamma(\frac{\nu}{2})} \frac{((\nu-2)\pi)^{\frac{n_2}{2}}\Gamma(\frac{\nu}{2})}{\Gamma(\frac{\nu+n_2}{2})(\det\Sigma_{22})^{-\frac{1}{2}}} \quad (26)$$

$$= \frac{\Gamma(\frac{\nu+n}{2})}{\Gamma(\frac{\nu+n_2}{2})} \frac{(\det\Lambda_{11})^{\frac{1}{2}}}{((\nu-2)\pi)^{\frac{n_1}{2}}} \quad (27)$$

と変形できる。次に \times の後ろのカーネル部分に着目すると、

$$\begin{aligned} & \left(1 + \frac{\Delta}{\nu - 2}\right)^{-\frac{\nu+n}{2}} \left(1 + \frac{\Delta_2}{\nu - 2}\right)^{\frac{\nu+n_2}{2}} \\ &= \left(1 + \frac{\Delta_2}{\nu - 2}\right)^{-\frac{\nu+n}{2}} \left(1 + \frac{\Delta_1}{\nu - 2 + \Delta_2}\right)^{-\frac{\nu+n}{2}} \\ &\times \left(1 + \frac{\Delta_2}{\nu - 2}\right)^{\frac{\nu+n_2}{2}} \end{aligned} \quad (28)$$

$$= \left(1 + \frac{\Delta_2}{\nu - 2}\right)^{-\frac{\nu+n_1}{2}} \left(1 + \frac{\Delta_1}{\nu - 2 + \Delta_2}\right)^{-\frac{\nu+n}{2}} \quad (29)$$

と変形できる。ここで両者を合わせて、さらに整理すると、

$$\begin{aligned} & \frac{\Gamma\left(\frac{\nu+n}{2}\right)}{\Gamma\left(\frac{\nu+n_2}{2}\right)} \frac{(\det\Lambda_{11})^{\frac{1}{2}}}{((\nu-2)\pi)^{\frac{n_1}{2}}} \\ &\times \left(1 + \frac{\Delta_2}{\nu - 2}\right)^{-\frac{\nu+n_1}{2}} \left(1 + \frac{\Delta_1}{\nu - 2 + \Delta_2}\right)^{-\frac{\nu+n}{2}} \end{aligned} \quad (30)$$

$$\begin{aligned} &= \frac{\Gamma\left(\frac{\nu+n}{2}\right)}{\Gamma\left(\frac{\nu+n_2}{2}\right)} \frac{(\det\Lambda_{11})^{\frac{1}{2}}}{((\nu-2) + \Delta_2)\pi)^{\frac{n_1}{2}}} \\ &\times \left(1 + \frac{\Delta_1}{\nu - 2 + \Delta_2}\right)^{-\frac{\nu+n}{2}} \end{aligned} \quad (31)$$

となる。これは多変量 Student t -分布の密度関数の形から、 $\alpha = \nu + n_2$ 、 $\beta = \nu + \Delta_2$ とすると、自由度 $\nu + n_2$ 、平均 $\mu_1 + \Sigma_{12}\Sigma_{22}^{-1}(X_2 - \mu_2)$ 、共分散 $\frac{\beta}{\alpha}\Lambda_{11} = \frac{\nu+(x_2-\mu_2)^T\Sigma_{22}^{-1}(x_2-\mu_2)}{\nu+n_2}(\Sigma_{11} - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{12}^T)$ の多変量 t 分布であることがわかる。

7 まとめ

本稿では、一般に裾の厚い金融市場のデータへの応用を踏まえ、深層 t 過程回帰モデルの提案を行った。本稿の貢献は次の通り。

- t 過程回帰モデルに必要な多変量条件付き t 分布の完全な導出
- 実証分析により深層 t 過程回帰モデルの有効性の確認
- 深層 t 過程の予測の不確実性と予測精度の考察

今後の展望として、理論的にはガウス過程、 t 過程を包含するより広いクラスである加法過程による回帰モデルなどへの拡張の余地などを検討すること、また実証的には、伝統的に回帰モデルによって構築されるマルチファクターモデルに対して適用することで、手法の安定性を検証することが挙げられる。

参考文献

- [1] Youngmin Cho and Lawrence K Saul. Kernel methods for deep learning. In *Advances in neural information processing systems*, pp. 342–350, 2009.
- [2] Jaehoon Lee, Jascha Sohl-dickstein, Jeffrey Pennington, Roman Novak, Sam Schoenholz, and Yasaman Bahri. Deep neural networks as gaussian processes. In *International Conference on Learning Representations*, 2018.
- [3] Benoit B Mandelbrot. The variation of certain speculative prices. In *Fractals and scaling in finance*, pp. 371–418. Springer, 1997.
- [4] Radford M Neal. Priors for infinite networks. In *Bayesian Learning for Neural Networks*, pp. 29–53. Springer, 1996.
- [5] Carl Edward Rasmussen. Gaussian processes in machine learning. In *Advanced lectures on machine learning*, pp. 63–71. Springer, 2004.
- [6] James R Schott. *Matrix analysis for statistics*. John Wiley & Sons, 2016.
- [7] Amar Shah, Andrew Wilson, and Zoubin Ghahramani. Student- t processes as alternatives to gaussian processes. In *Artificial Intelligence and Statistics*, pp. 877–885, 2014.

ビットコイン価格時系列の統計的性質

Statistical properties of Bitcoin time series

高石哲弥

Tetsuya Takaishi

広島経済大学

Hiroshima University of Economics

Abstract: 本研究では、1分ごとのビットコイン価格データをもとに、その収益率時系列の統計的性質を調べた。収益率時系列の性質は他の金融時系列によく見られるファットテイル分布となっていることが分かった。ボラティリティの時間変動は GARCH 及び RGARCH モデルによって解析した。その結果、ボラティリティの持続性は大きく、またボラティリティプロセスの非対称性は小さいことが分かった。尖度は非常に大きい、時間スケールが大きくなるにしたがってゆっくりとガウス分布の値に近づくことが分かった。マルチフラクタル解析からは、一般化ハースト指数 $h(q)$ を決定した。一般化ハースト指数は q の値に依存し、マルチフラクタル性を持つことがわかった。更に、絶対値収益率のべき乗の自己相関を調べたところ、べき指数が約 0.4 のところで自己相関が最大となり、ビットコイン価格時系列にテイラー効果が存在することが分かった。

1. はじめに

ビットコインはサトシ・ナカモトという人物によって 2008 年に投稿された論文[1]に基づき考案された仮想通貨である。2009年にはビットコインのソフトウェアである Bitcoin Core が配布され、ブロックチェーンの最初のブロックである genesis block の生成を経て、ビットコインの運用が開始された。その後、Mt.Gox の破綻等の出来事が発生したが、ビットコインのネットワークそのものは堅牢で完全な停止に陥ったことはない。ビットコインのネットワークはピアツーピアで構成され、中央集権的機関によらずオンライン決済が実行される。取引履歴はブロックチェーンと呼ばれる公開台帳に記録されてゆく。このビットコインの中核技術であるブロックチェーンは、仮想通貨以外の金融インフラの技術として注目を集め、FinTech における基幹技術として発展を続けている。

ビットコインは 2017 年 12 月に 1 BTC あたり 200 万円を超えるまで高騰したが現在 (10 月 1 日) は約 75 万円である。それでも、多くの仮想通貨が存在する中で、時価総額は 1 位であり、13 兆円を超える。この注目を集めるビットコイン価格は様々な側面から学術的な研究もされてきている (例えば、[2])。

本研究では、ビットコイン価格に注目し、その収

益率時系列の統計的性質を調べる。また、GARCH モデルによってボラティリティの時間変動の解析やマルチフラクタル解析[3]による時系列の長期記憶性、テイラー効果[4]についても研究を行う。

2. ビットコイン価格

本研究では、Bitcoin Price Index[5]の 1 分毎の価格データを利用し解析を行った。Bitcoin Price Index は 2013 年 9 月より作成が始まったインデックスで、世界のビットコイン取引所のうち CoinDesk の提示する条件 (国際的な取引サービス、最低取引サイズが 1500 USD 以下など) にあった取引所の価格の単純平均で作成されている。本研究では、2014 年 1 月 1 日から 2017 年 12 月 31 日までの 1 分毎の価格データを利用した。価格を $P(t)$ とする

と、収益率は $R_{\Delta t}(t) = \ln P(t) - \ln P(t - \Delta t)$ で表される。ここで、 Δt はサンプリング周波数である。図 1 は 1 分ごと、つまり $\Delta t = 1\text{-min}$ の収益率の分布である。非常に裾野の厚いファットテイル分布となっている。

図 2 は様々なサンプリング周波数 Δt での収益率の尖度を表している。横軸がサンプリング周波数 Δt にあたる。 $\Delta t = 1$ では、尖度は 1000 に近いが、 Δ

t が大きくなると尖度はゆっくりと小さくなっている。 Δt が約 20,000min つまり約 2 週間で尖度は 3 に近づいている。このことから、ビットコイン収益率は時間スケールが大きくなると正規分布の尖度である 3 に近づいていくが、その近づき方は非常に遅いことがわかる。

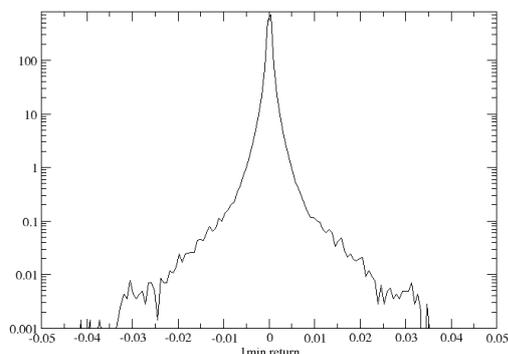


図 1 ビットコイン収益率分布

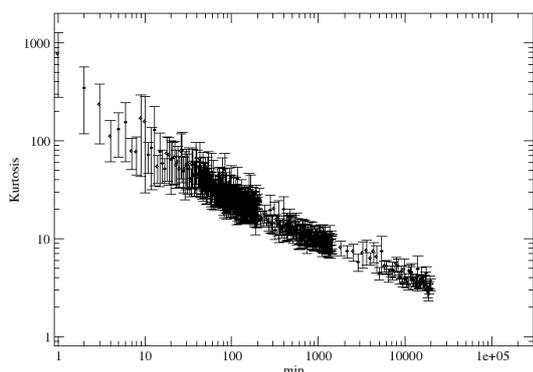


図 2 ビットコイン収益率の尖度

図 3 はビットコイン収益率の歪度をサンプリング周波数 Δt の関数で表している。 Δt が小さいところでは歪度は負となっている。 Δt が大きくなるとゼロに近づいている。ゼロへの近づき方は尖度と同様にゆっくりとしており、 Δt が約 10000-min(1 週間)で歪度はゼロとなっている。

図 4 は収益率の自己相関関数を表している。自己相関は 5 分程度で無くなっていることがわかる。一方、図 5 は絶対値収益率の自己相関関数のグラフで、自己相関はゆっくりと減少しており、長期記憶性を表している。絶対値収益率の d 乗に対して自己相関を調べた結果は 5 章のテイラー効果の所で詳しく述べる。

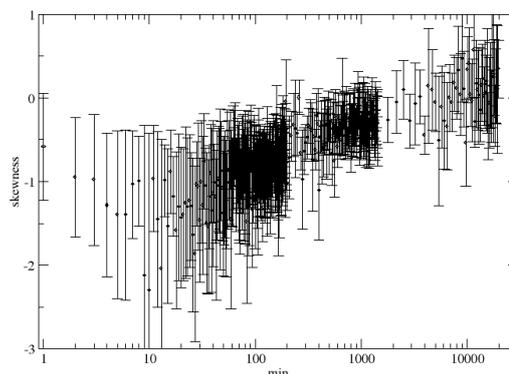


図 3 ビットコイン収益率の歪度

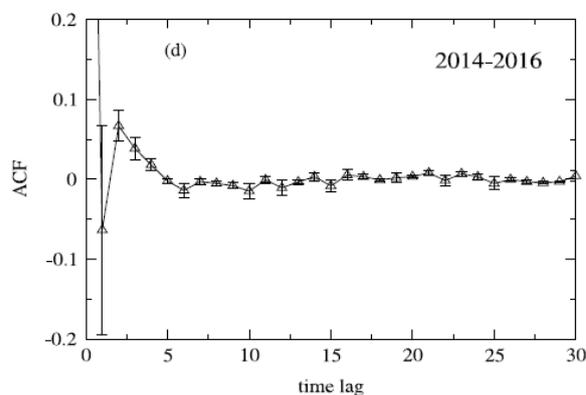


図 4 収益率の自己相関関数[6]

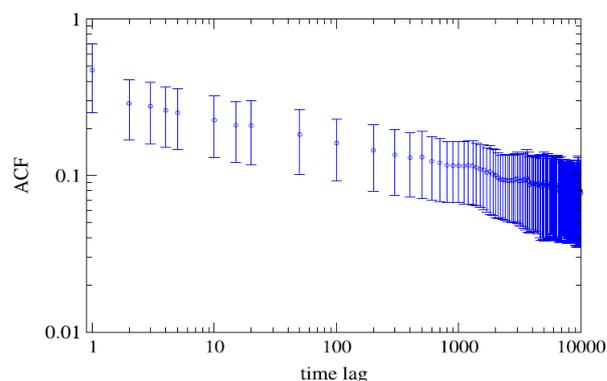


図 5 絶対値収益率の自己相関関数[6]

3. GARCH モデルによる解析

本研究では、ビットコイン価格の日次収益率に対して、GARCH 型モデルを使いボラティリティの持続性を調べた。ここでは、GARCH モデル[7]とボラティリティに非対称性を取り入れた RGARCH モ

デル[8,9]を利用した。これらのモデルでは、収益率 $r_t = \sigma_t \varepsilon_t$ として表したとき、ボラティリティプロセスが以下のように表される。

- GARCH モデル

$$\sigma_t^2 = \omega + \alpha r_t^2 + \beta \sigma_{t-1}^2$$

- RGARCH モデル

$$\sigma_t^2 = \frac{\omega + \alpha r_t^2 + \beta \sigma_{t-1}^2}{1 + \delta r_{t-1}}$$

ここで、 $\alpha, \beta, \omega, \delta$ はモデルパラメータである。

また、 ε_t は $N(0,1)$ に従う正規乱数を仮定した。 r_t は日次収益率であるが、 $100 \times R_{1440}(t)$ で定義したデータを利用した。

図6の一番上の図は日次収益率の時間変動を表しており、ボラティリティクラスターが現れていることが分かる。表1は日次収益率データから求めたモデルのパラメータである。パラメータ推定にはベイズ推定を用いた[10-13]。RGARCHモデルのパラメータ δ はボラティリティの非対称性を導入するパラメータであるが、非常に小さい値となっている。その為、GARCHモデルとRGARCHモデルで大きな違いはなく、 α, β, ω の値も似た値になっている。また、 $\alpha + \beta$ の値は、1に近く、ボラティリティの持続性が高いことを示している。図6の下部2つの図は推定されたGARCHとRGARCHモデルによって推定された σ_t^2 を図示したものである

が、ほとんど違いは見取れない。これらのことから、ビットコインの日次収益率変動は株価等のボラティリティと同様にボラティリティの持続性が高い一方で、ボラティリティ非対称性は小さいと考えられる。

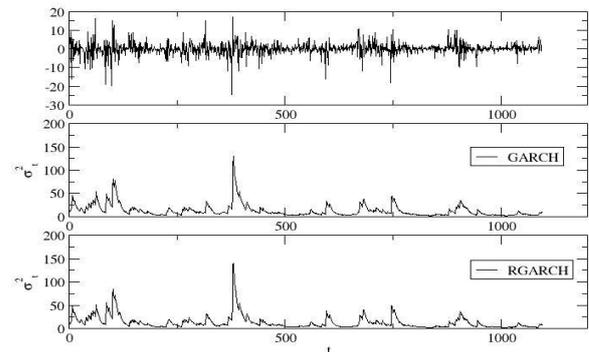


図6 収益率時系列と推定されたボラティリティ時系列

表1：推定されたモデルパラメータ。括弧の中は標準偏差を表している。

	GARCH	RGARCH
α	0.114(18)	0.116(19)
β	0.878(19)	0.875(20)
ω	0.239(78)	0.249(80)
δ	----	0.0053(47)
AIC	5539.50	5541.55
DIC	5535.68	5536.73

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[13]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。

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

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、 ν 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。

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

(2) 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。

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

(3)

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。

$$F_q(s) = \left(\frac{1}{2N_s} \sum_{\nu=1}^{2N_s} [F^2(s, \nu)]^{q/2} \right)^{1/q} \quad (4)$$

もし、時系列が長期のべき的相関を持つなら、(4) 式は以下のように振る舞うことが期待される。

$$F_q(s) \sim s^{h(q)} \quad (5)$$

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、上記の手続きは、Detrended fluctuation analysis[14]と同一となり、 $h(2)$ 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 (5) 式の振る舞いから一般化ハースト指数 $h(q)$ を求める。

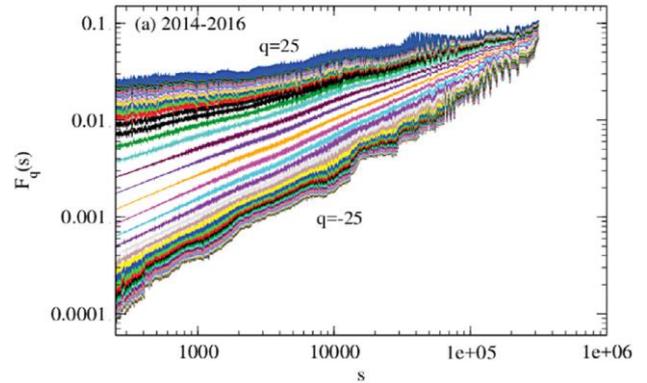


図7 揺らぎ関数 $F_q(s) \sim s^{h(q)}$ [6]

図7は2014年～2016年までのデータを利用して揺らぎ関数(4)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。傾きは q に依存していることから、マルチフラクタル性があることになる。

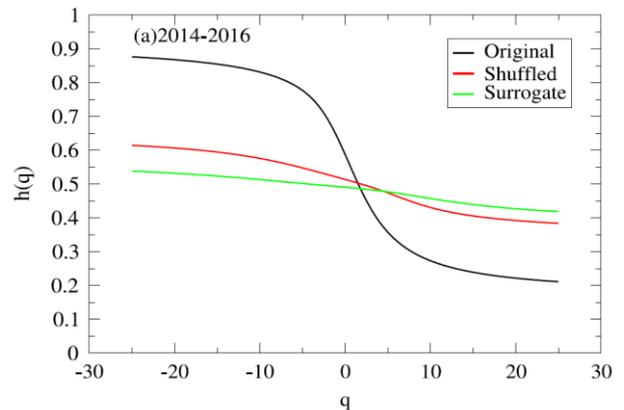


図8 一般化ハースト指数 $h(q)$ [6]

図8は図7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(Original)。 q が負の領域で0.5より大きな値を取り、正の領域では0.5よりも小さい。ハースト指数を求めると $h(2) = 0.475$ とガウス時系列の0.5に近い値になったが、 $h(q)$ が q に大きく依存し、ビットコイン時系列はガウス時系列の性質だけでは表されないことがわかる。また、 q が負の領域では0.5よりも大きく、 q が負の時系列で見ると長期記憶性があることが分かった。図8中の(Shuffled)は、時系列をランダムにシャッフルし、時系列相関を取り除いた時系列から $h(q)$ を求めた

ものである。この時系列には、ファットテイル分布の性質が残っているが、 $h(q)$ の変動は小さくなっており、マルチフラクタル性はファットテイル性よりも時系列相関の影響によることが大きいと思われる。(Surrogate)は線形の相関のみを維持した時系列の場合であるが、この場合も $h(q)$ の変動は小さくなっており、線形相関以外の影響がマルチフラクタル性に関わっていると思われる。

5. テイラー効果

Taylor[4]は40個の様々な金融資産について、収益率の2乗と収益率の絶対値の自己相関を比較した。そして、それらの値が有意に正の値を取っており、また多くのケースで収益率の絶対値の自己相関の方が収益率の2乗のものよりも大きくなることを発見した。その後、Dingら[15]は、S&P500 Indexの収益率を使い、収益率の絶対値のべき乗について自己相関を調べた。その結果、S&P500 Indexの収益率はべき指数が約1の時に自己相関が最大になると結論付けた。このような収益率の絶対値の自己相関が収益率の2乗のものよりも大きくなることをGrangerとDing[16]はテイラー効果(Taylor effect)と呼んだ。その後の実証研究から、収益率のべき指数が1以外の場合に自己相関が最大になる例も発見された。例えば、DingとGranger[17]は、株価収益率の場合はべき指数が1の時に自己相関が最大になるが、為替収益率の場合は1/4の時に最大となることを発見した。一方、Dacorognaら[18]はUSD-DEMとUSD-FRFペアの収益率に対しては、べき指数が1/2の時に最大となることを発見した。このテイラー効果についてビットコイン時系列を用いて研究を行った。尚、このテイラー効果の研究は首都大学東京の足立高德氏との共同研究である[19]。

以下で定義される自己相関関数を絶対値収益率のd乗に対して計算をし、テイラー効果を調べる。

$$\rho_d(\tau) = \frac{\frac{1}{N} \sum_t (|r(t+\tau)|^d - \langle |r|^d \rangle) (|r(t)|^d - \langle |r|^d \rangle)}{\sigma_{|r|^d}^2} \quad (7)$$

ここで、 $\sigma_{|r|^d}^2$ は $|r|^d$ の分散、 τ はタイムラグである。

また、 $\langle * \rangle$ は*の平均を表している。

図9はd=1と2の場合の自己相関関数を図示しており、収益率の2乗よりも絶対値収益率の自己相関の方が大きい結果となっており、テイラー効果が存在していることになる。

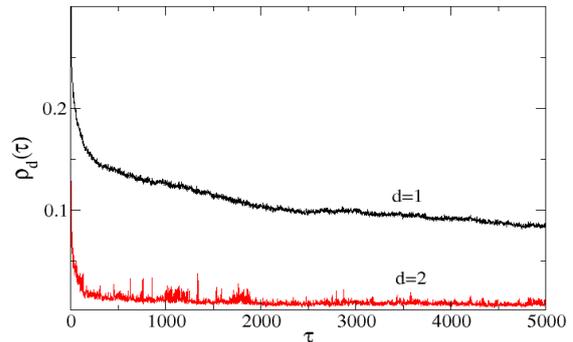


図9 ビットコインの $\rho_1(\tau)$ と $\rho_2(\tau)$ [19]。ラグ τ の単位は分である。

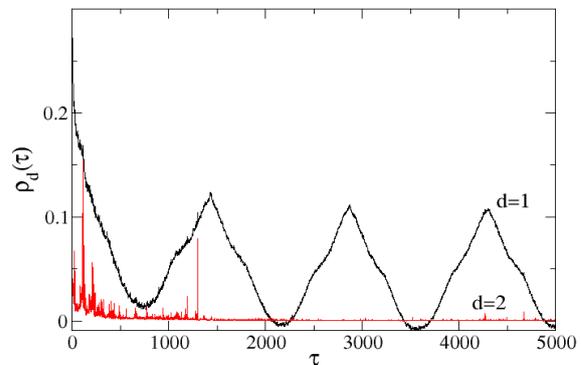


図10 ビットコインの $\rho_1(\tau)$ と $\rho_2(\tau)$ [19]。

本研究では、比較のため為替レート収益率についても解析を行った。図10はEUR-GBPペアの自己相関関数を表している。為替レートの場合は日次の周期性が現れている。但し、べき指数dを大きくすると周期性は小さくなり、d=2ではほとんど見られなくなった。

図11は様々なべき指数において自己相関計算 d_{max} はし、ラグごとに自己相関を最大にするべき指数を求めた結果を表している。図10の最上部の図はビットコイン時系列における自己相関を最大化するべき指数をラグの関数で表したものである。ラグ $\tau=1$ 分で d_{max} は約0.5であり、ラグが大きくなると徐々に小さくなっている。一方、図11の下部3つのグラフは3種類ペアの為替レートについて d_{max} を求めたものであるが、図10と同様に d_{max} にも日次の周期性が現れている。

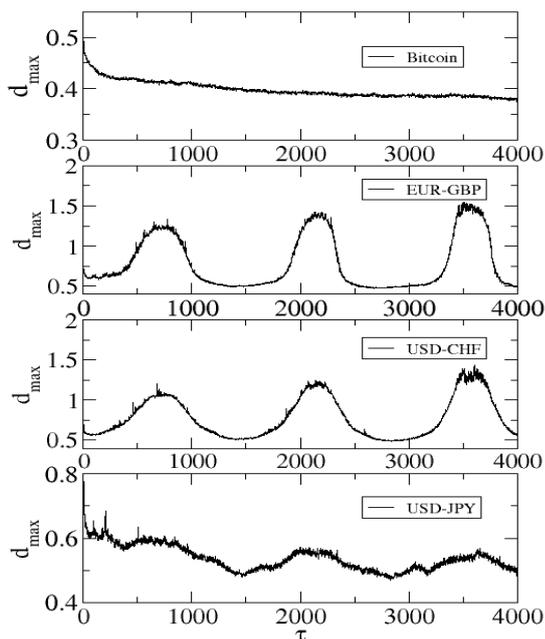


図 11 自己相関を最大にするべき指数 d_{\max} [19]。横軸はラグ τ (分) を表している。

6. まとめ

本研究では、1 分毎のビットコイン価格データを解析した。収益率分布はファットテイルとなっており、尖度は高い値となっている。また、収益率の自己相関は短期であるが、絶対値収益率の自己相関は長期である。GARCH タイプモデルの解析からは、ボラティリティクラスターリングがあり、ボラティリティの持続性が高いことが分かった。これらの性質は、他の金融資産価格に共通に見られる Stylized facts の性質と一致する。その他の性質として、ビットコイン価格時系列はマルチフラクタル性やテイラー効果を持つことが分かった。

謝辞

本研究の一部は JSPS 科研費 JP12345678 の助成による。

参考文献

[1] N. Satoshi, Bitcoin: A peer-to-peer electronic cash system, [https:// bitcoin.org/bitcoin.pdf](https://bitcoin.org/bitcoin.pdf), (2008)
 [2] A.F. Bariviera, M.J. Basgall, W. Hasperué, M. Naiouf, Some stylized facts of the bitcoin market, *Physica A* 484 (2017) 82–90.

[3] J.W.Kantelhardt et al., Multifractal detrended fluctuation analysis of nonstationary time series, *Physica A* 316, 87–114, (2002).
 [4] S. J. Taylor, *Modelling financial time series*, John Wiley & New jersey, 1986.
 [5] CoinDesk, <http://www.coindesk.com/>
 [6] T. Takaishi, Statistical properties and multifractality of bitcoin, *Physica A* 506 507–519, (2018)
 [7] T. Bollerslev, Generalized autoregressive conditional heteroskedasticity, *Journal of Econometrics* 31, 307–327, (1986)
 [8] T. Takaishi, Rational GARCH model: An empirical test for stock returns, *Physica A*, 473, 451–460 (2017).
 [9] T.Takaishi, Volatility estimation using a rational GARCH model, *Quantitative Finance and Economics*, 2(1), 127–136, (2018)
 [10] T. Takaishi, An adaptive Markov chain Monte Carlo method for GARCH model, *Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering. Complex Sciences* 5, 1424–1434, (2009)
 [11] T. Takaishi, Bayesian estimation of GARCH model with an adaptive proposal density, *New Advances in Intelligent Decision Technologies, Studies in Computational Intelligence* 199, 635–643, (2009)
 [12] T. Takaishi, Bayesian inference on QGARCH model using the adaptive construction scheme, *Proceedings of 8th IEEE/ACIS International Conference on Computer and Information Science* 525–529, (2009)
 [13] T. Takaishi, Bayesian inference with an adaptive proposal density for GARCH models, *Journal of Physics: Conference Series, Vol. 221*, 012011, (2010)
 [14] C.K. Peng, et al., Mosaic organization of DNA nucleotides, *Phys. Rev. E* 49, 1685, (1994)
 [15] 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)
 [16] C. W. J. Granger, Z. Ding, Some properties of absolute return: An alternative measure of risk, *Annales d’Economie et de Statistique* 67–91, (1995)
 [17] Z. Ding, C. W. Granger, Modeling volatility persistence of speculative returns: a new approach, *Journal of econometrics* 73 (1), 185–215, (1996)
 [18] M. Dacorogna, R. Gencay, U. Müller, O. Pictet, R. Olsen, *An introduction to high-frequency finance*, Academic Press, 2001.
 [19] T.Takaishi, T.Adachi, Taylor effect in Bitcoin time series, *Economics Letters* 172, 5–7, (2018)

一般顧客の集合知による外国為替交換レート予測

Prediction of Foreign Exchange Rates
by Collective Knowledge of Individual Traders

矢野 和洞^{1*} 鈴木 丈裕¹ 鈴木 智也^{1,2}
Kazuto YANO¹ Takehiro SUZUKI¹ Tomoya SUZUKI^{1,2}

¹ 茨城大学大学院理工学研究科

¹ Graduate School of Science and Engineering, Ibaraki University

² コラボウィズ株式会社

² CollabWiz. Inc

Abstract: Foreign-exchange trading (FX) is well known as an asset management method like stock investment. Individual traders basically send their orders to an FX broker, and the FX broker executes cover transactions with global megabanks to prevent the price-fluctuation risk. If it is possible to foresee the future price movement, FX brokers can make their cover transactions more efficient. Fortunately, FX brokers can see the trading positions of their customers. If each customer has a little predictive power, the aggregation of all customers' positions might improve the predictive power in terms of the wisdom of crowds. From this viewpoint, we tried to extract the collective knowledge from all customers and applied it to improve cover transactions. As a result, our idea worked well to make FX brokerage business less risky and more profitable.

1 はじめに

外国為替証拠金取引 (Foreign Exchange trading : FX) では、同取引を扱う業者 (以下、FX 業者) と顧客の間で取引が行われる。FX 業者は顧客からの注文を自ら抱えてしまうと価格変動に伴う損失リスクを負うことになるため、このリスクを限定するために自らも別の金融機関や市場に対して顧客と反対の取引を行う。これをカバー取引と呼ぶ。カバー取引によって、FX 業者の市場変動による損失リスクが解消され何らかの手段で収益が確定する。しかし将来の価格を予測し、事前に業者が損失リスクを回避できることが分かっているならば、顧客の取引に対しカバー取引を行わない方が合理的である。そこで、価格予測を通じて、FX 業者が損失を被ると判断すればカバー取引を行い、利益が発生すると判断すればカバー取引を先延ばしする、という戦略を考える。顧客の取引履歴情報を利用することで他者よりも有効な価格予測が可能になるかもしれない。またたくさんの顧客の売買動向を表す取引履歴には、集合知 [1] の観点からある程度の価格予測力が秘められていると予想される。そこで本研究では取引履

履歴情報を「アマチュア集団による集合知」として未来価格の予測に利用し、FX 業者の立場 [2] になって、顧客の取引履歴情報 [3] を用いた FX 市場の価格予測を行い、上記戦略の有用性を検証する。

2 集合知による取引価格予測

集合知とは他人の知恵を統合することで、物事の判断能力を向上できるという概念である。集合知が大きな力を発揮する理由として、多様性予測定理 [1] がある。ある問題の答えを予測する時、全 M 個の予測モデルを用いるとする。第 i 番目のモデルによる予測値を \hat{x}_i 、多数決による最終的な予測値を $E[\hat{x}] = \frac{1}{M} \sum_{i=1}^M \hat{x}_i$ 、正解値を x とすると以下が成り立つ。

$$(x - E[\hat{x}])^2 = \frac{1}{M} \sum_{i=1}^M (x - \hat{x}_i)^2 - \frac{1}{M} \sum_{i=1}^M (\hat{x}_i - E[\hat{x}])^2 \quad (1)$$

ここで、左辺は「多数決の予測誤差」、右辺第 1 項は「各予測モデルの平均予測誤差」、右辺第 2 項は「予測モデルの分散値」を示している。したがって予測モデルの分散値 (多様性) が大きいほど、多数決の予測誤差

*連絡先：茨城大学大学院理工学研究科知能システム工学専攻
〒316-8511 茨城県日立市中成沢町 4-12-1
E-mail: 18nm507y@vc.ibaraki.ac.jp

注文番号	発注日時	注文種別	取引区分	通貨ペア	売買	約定レート	注文レート	注文数量	注文条件	有効期限	トレード開始注文チャタリス4第一受渡	第二受渡	約定日時	約定レート	約定口	口番号	
2.83E+09	3625.6	1	新規	USD/JPY	1	102.225	102.1	10000	定指値	#####			3625.6	0000.2	1.75E+09		
1.95E+09	6237.5	3	決済	USD/JPY	1	102.225	102.15	1000	定指値	#####	3.70E+09		6237.5	0000.2	2.05E+09		
1.87E+09	2151.6	4	新規	USD/JPY	1	102.225	102.221	5000	定指値	#####	2.4E+09		2.4E+09	2.61E+09	2151.6	0000.2	2.48E+09
3.99E+09	1929.6	3	決済	USD/JPY	1	102.225	102.09	10000	定指値	#####	1.63E+09		1929.6	0000.2	2.66E+09		
2.91E+09	5155.2	2	新規	USD/JPY	2	102.165	102.137	10000	定指値	#####	2.32E+09		5155.2	0000.2	2.7E+09		
3.69E+09	4814.6	1	新規	USD/JPY	1	102.225	102.1	10000	定指値	#####			4814.6	0000.2	9.91E+09		
1.31E+09	4343.8	4	新規	USD/JPY	2	102.165	102.087	1000	定指値	#####	3.39E+09		3.39E+09	4.04E+09	4343.8	0000.2	1.03E+09
1.54E+09	3644.6	4	新規	USD/JPY	1	102.225	102.2	10000	定指値	#####	3.95E+09		3.95E+09	3.79E+09	3644.6	0000.2	1.21E+09

図 1: 取引履歴データの一部

が縮小する。また機械学習を用いた価格予測の分野でも集合知が機能している事例がある [4, 5, 6]。

FX 業者は膨大な顧客の取引履歴情報を所持しており、この情報には顧客による未来価格の予測が含まれている。顧客一人一人の予測力が乏しいとしてもそれが膨大に集まれば、多様性予測定理の観点から予測力を向上できる可能性がある。

図 1 に取引履歴情報の一部を示す。顧客の集合知を予測に利用するために、顧客の未来価格の予測が強く反映されている「指値注文」のみに着眼する。予測に用いる説明変数は、「取引件数」、「取引数量」、「買い件数と売り件数の差」(以下、net 件数と表す)、「買い数量と売り数量の差」(以下、net 数量と表す)の 4 種とする。取引件数と取引数量は市場の盛り上がりを示すものである。net 件数および net 数量が正ならば、将来の価格は上昇すると予想している顧客が多いことを示す。指値注文による取引が約定した時点を観測点とし、そこから 1, 5, 15, 30 分前(以下、 B で表す)の取引履歴を利用して 5, 15, 30 分後(以下、 F で表す)までの取引価格(仲値)を予測する。

3 集合知を用いた為替カバー取引

2 で示した予測を利用した FX 業者のカバー取引に関する新たな戦略を考案する。その戦略を用いてシミュレーションを行う時の評価指標として、勝率、総利益、最大ドローダウン、そして総利益に対する最大ドローダウンの割合を用いる。勝率は価格変化の方向を当てることができた割合であり価格変化量を考慮しない。総利益を評価するために、相対取引業者が顧客の取引に対し必ず即時カバー取引を行う戦略(以下、従来法 1 と呼ぶ)、必ずカバー取引を先延ばす戦略(以下、従来法 2 と呼ぶ)の 2 つの単純な戦略で利益計算を行う。さらに予測結果から即時カバー取引を行うかどうかを判断する戦略(以下、提案法と呼ぶ)と比較する。

上記 3 つの戦略の総利益計算方法を示す。図 2 はカバー取引を行った場合、FX 業者が得られる損益を表している。顧客が取引をする際、買値と売値(以下、レートと呼ぶ)が存在し、通常買値の方が売値よりも高い。

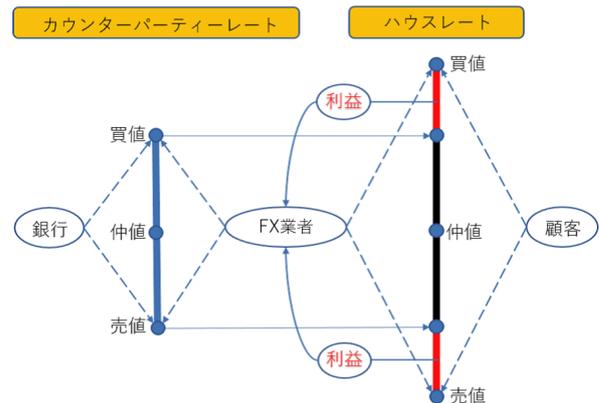


図 2: FX 業者の利益

このレートは FX 業者が複数の金融機関が提示する価格を集約して生成した価格を顧客に提示しており、これをハウスレートと呼ぶ。FX 業者がカバー取引を行う取引先(投資銀行や証券会社など)のことをカウンターパーティーと呼ぶ。カバー取引を行う際にはカウンターパーティーの提示しているレート(以下、カウンターパーティーレート)によって為替差損益が発生する。すなわち FX 業者が一連の取引によって得られる損益はカウンターパーティーレートとハウスレートの差になる。しかし、ハウスレートとカウンターパーティーレートは極めて頻繁に変化するので、損益計算を簡単にするためにハウスレートとカウンターパーティーレートの差(以下、為替差損益)を常時 0.3 銭に固定して考える。また、取引数量 A が多いほど取引手数料による利益は拡大するため、1 取引あたりの利益 P_1 は以下となる。

$$P_1 = A \times 0.003 \quad (2)$$

ここで A は 1 取引あたりの取引数量である。従来法 1 では取引が発生するごとに P_1 を足し合わせることで総利益 R を求める。

カバー取引を先延ばしにした場合は、その後の価格変化によって損益が決まる。例えば、FX 業者がドル売りポジションを持ち、カバー取引を行わないままドルの価格が上昇すれば FX 業者は損をする。この損益は取引が行われた観測点から予測点までの間に变化した $delta_price$ と、取引数量 A で決まる。さらに式 (1) の為替差損益による利益が加算されるので 1 取引あたりの利益 P_2 は以下となる。

$$P_2 = (delta_price \times A) + (A \times 0.003) \quad (3)$$

従来法 2 では取引が発生するごとに P_2 を足し合わせることで総利益 R を求める。

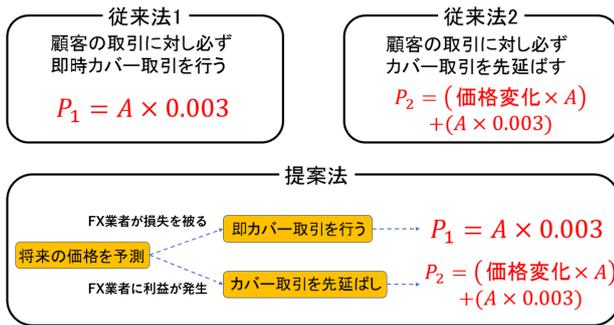


図 3: 各戦略におけるそれぞれの総利益の計算方法

しかし FX 業者がカバーの先延ばしにより損すると判断できれば即時にカバー取引をすることで式 (1) によって利益を得る。つまり、予測結果に応じて即時にカバー取引をしない方が得であれば式 (2) を用い、即時にカバー取引をした方が得であれば式 (1) に切り替える。提案法では、これらの総和を計算することで総利益 R を求める。図 3 にそれぞれの戦略における利益計算方法を示す。

4 シミュレーション

使用するデータは、2016 年 8 月から 2017 年 12 月までのドル円の取引履歴情報と価格の値動きである。学習期間を 1 ヵ月およびテスト期間を 1 週間とし、予測の勝率、総利益、最大ドローダウンを算出する。為替の価格変動は約 1 週間ごとに変化する傾向があり、2016 年 8 月から 2017 年 12 月のシミュレーション期間において 1 週間ずつシフトしながら学習とテストを行う。このシミュレーションは計 69 回行われ、すべての B と F の組み合わせについて同様のシミュレーションを行う。なお、本稿の予測モデルには最も基本的な線形回帰を用いている。今後は線形回帰以外の予測モデルによるシミュレーションも検討している。

5, 15, 30 分後を予測した勝率をそれぞれ図 4~6 に示す。 $B = 15$ および $F = 5$ の組み合わせだけが 50% を越えているが、他の場合ではわずかに 50% を下回る結果となり、予測が機能していない。また図 7 は $B = 15$ および $F = 15$ における計 69 回のシミュレーションで、勝率の安定性を評価するグラフである。これより勝率が 55% のように高い時もあれば 40% と低い時もあり、勝率が安定していない。やはり外国為替の価格予測は非常に困難である。この低い勝率については以後再び触れる。

5, 15, 30 分後を予測した総利益をそれぞれ図 8~10 に示す。特に $\{B, F\} = \{15, 15\}$ と $\{30, 15\}$ におい

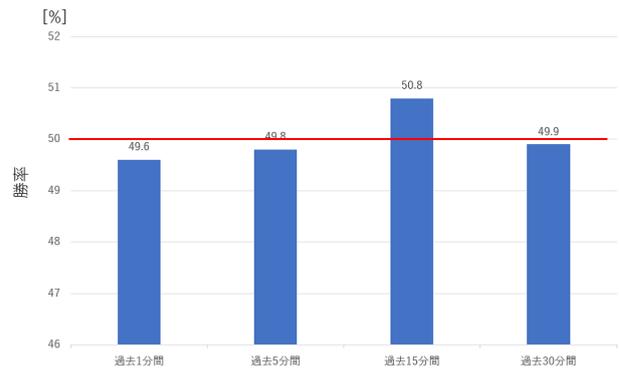


図 4: 5 分後を予測した場合の勝率

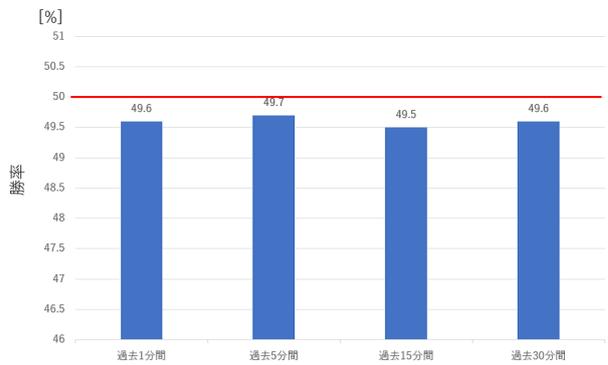


図 5: 15 分後を予測した場合の勝率

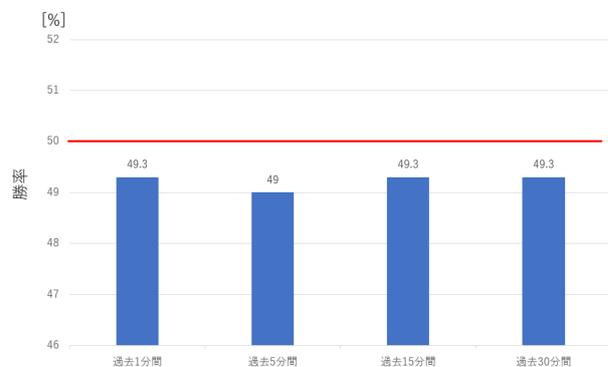


図 6: 30 分後を予測した場合の勝率

て従来法を上回る良好な総利益を示している。つまり予測対象として 15 分後程度が良い印象である。なお、 $\{B, F\} = \{15, 15\}$ における総利益の累積を図 11 に示す。提案法と従来法 2 は同じように推移するが、提案法の方が大きな利益を得る機会を捉え、大きな損失を被る機会を回避している様子が伺える。図 11 で得られた総利益の変化量を図 12 に示す。従来法 2 よりも提案法の方が変動が小さく安定性に優れている。5, 15, 30 分後を予測した総利益をそれぞれ図 8~10 に示す。

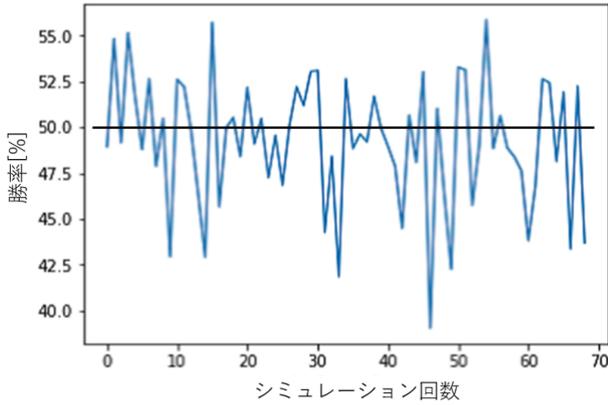


図 7: $B = 15$ および $F = 15$ における勝率の変化

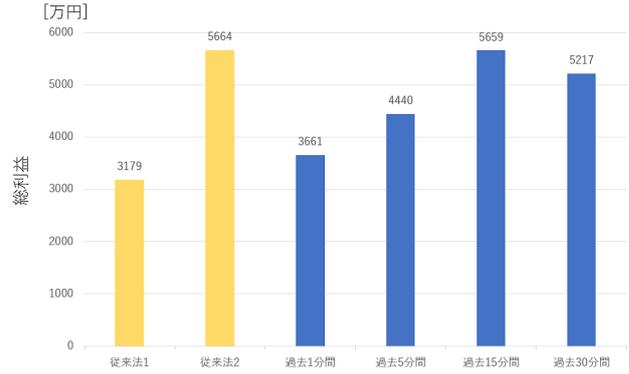


図 10: 30分後を予測した場合の総利益

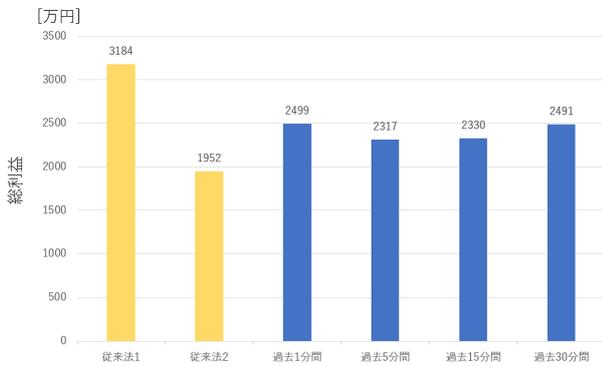


図 8: 5分後を予測した場合の総利益

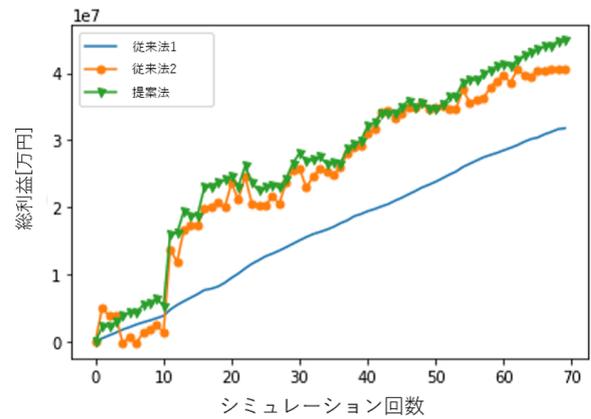


図 11: $B = 15$ および $F = 15$ における総利益の累積

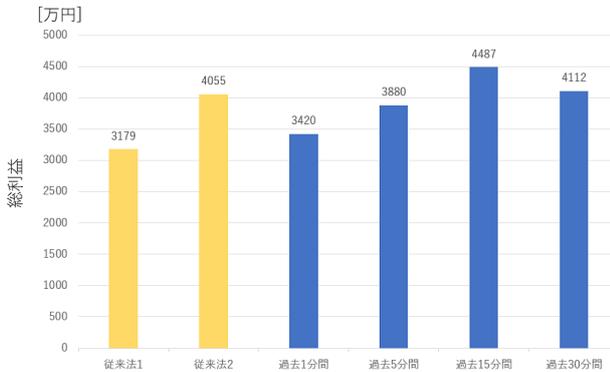


図 9: 15分後を予測した場合の総利益

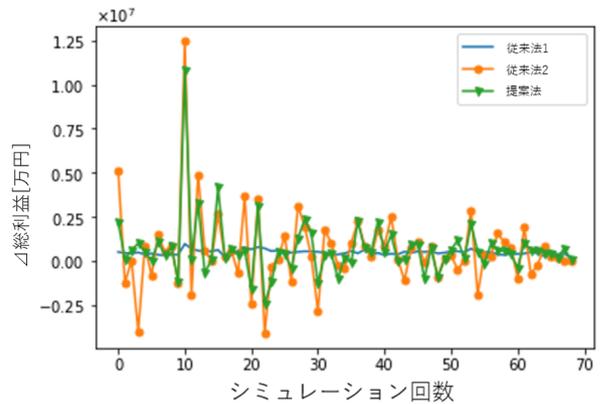


図 12: 図 11 における総利益の変化量

特に $\{B, F\} = \{15, 15\}$ と $\{30, 15\}$ において従来法を上回る良好な総利益を示している。つまり予測対象として15分後程度が良い印象である。なお、 $\{B, F\} = \{15, 15\}$ における総利益の累積を図 11 に示す。提案法と従来法 2 は同じように推移するが、提案法の方が大きな利益を得る機会を捉え、大きな損失を被る機会を回避している様子が伺える。図 11 で得られた総利

益の変化量を図 12 に示す。従来法 2 よりも提案法の方が変動が小さく安定性に優れている。

5, 15, 30 分後を予測した場合の最大ドローダウンをそれぞれ図 13~15 に示す。すべての場合で提案法は従来法 2 より最大ドローダウンが低く、リスクが低いことを示している。これは集合知による予測により大

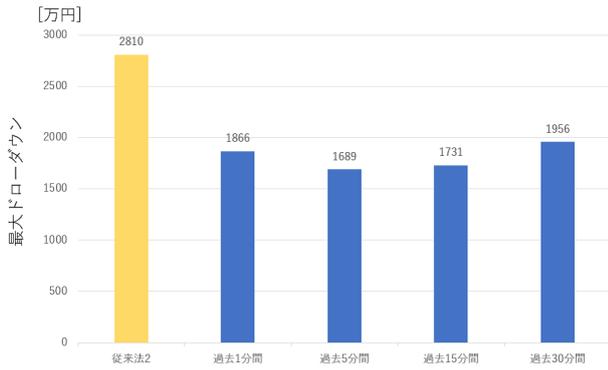


図 13: 5分後を予測した場合の最大ドローダウン

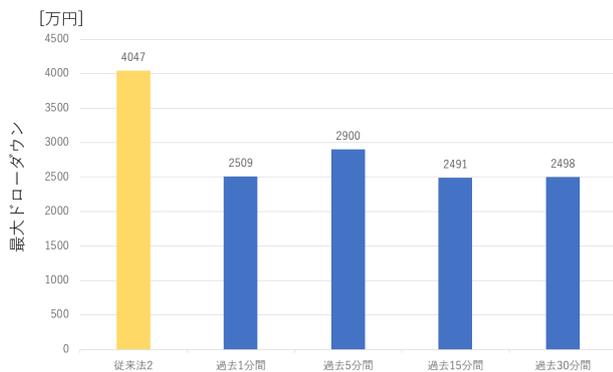


図 14: 15分後を予測した場合の最大ドローダウン

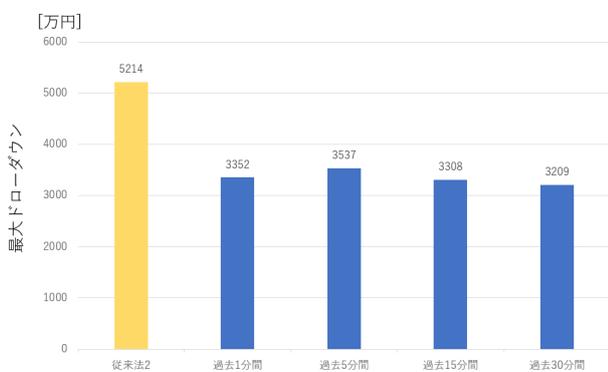


図 15: 30分後を予測した場合の最大ドローダウン

大きな損失を回避できたためカバー戦略の安定性が向上できたと考えられる。図 16 は $\{B, F\} = \{15, 15\}$ における最大ドローダウンの変化を示す。従来法 2 よりも提案法の方が値は低く安定している様子が分かる。

最後に、リスク当たりの収益率を評価すべく、総利益/最大ドローダウンを計算した結果を図 17~19 に示す。結果として、 B と F 全ての組み合わせにおいて提案法は従来法よりも優れたパフォーマンスを示している。特に $\{B, F\} = \{15, 15\}$ においては最大ドロー

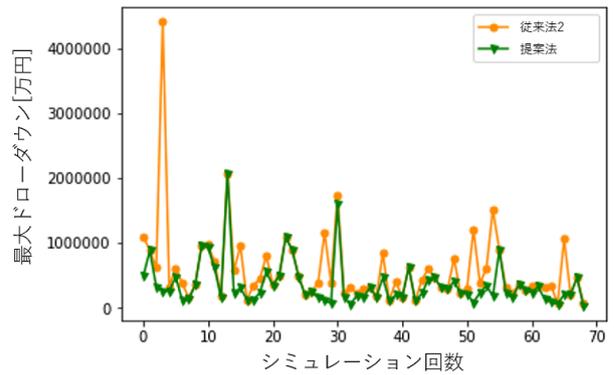


図 16: $B = 15$ および $F = 15$ における最大ドローダウンの変化

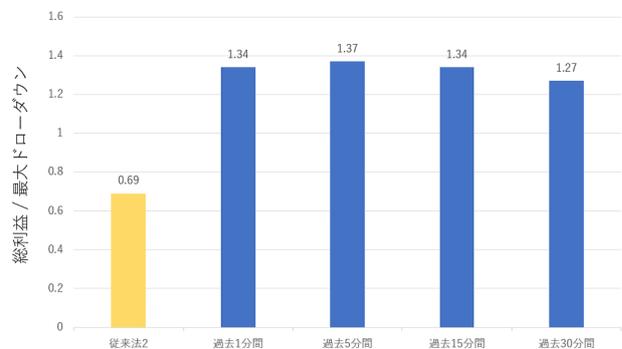


図 17: 5分後を予測した場合の総利益/最大ドローダウン

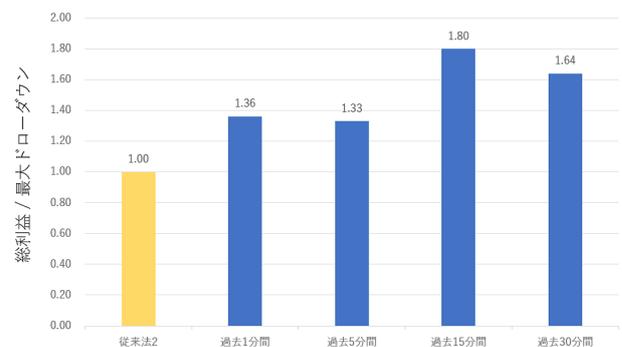


図 18: 15分後を予測した場合の総利益/最大ドローダウン

ダウンの 1.8 倍の総利益を得ている。以上を勘案すると、勝率は基準である 50% に満たないが、総利益は低くなく、最大ドローダウンについても良好である。また図 11 に示すように大きな利益を得る機会を捉え、大きな損失を被る機会を回避できている。このような結果から考察すると、総利益が大きく変化する取引、す

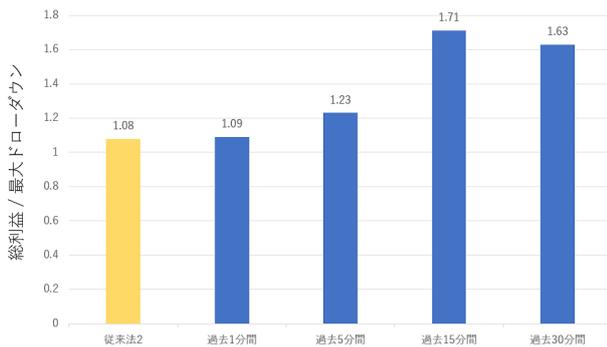


図 19: 30 分後を予測した場合の総利益/最大ドローダウン

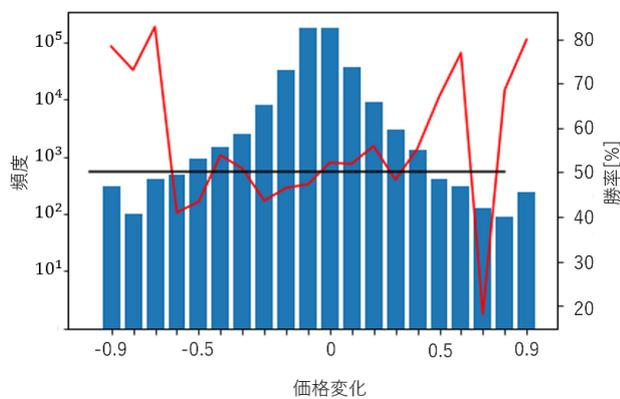


図 20: $B = 15$ および $F = 15$ における価格変化幅 (真値) と勝率の関係

なわち価格変化が大きい時ほど予測が機能しやすいと考えられる。そこで 0.1 毎に価格変化帯を設け、それぞれにおいて勝率を計算する。この結果を図 20 に示す。価格変化が小さい領域ではほぼ 50% の勝率であるが、価格変化が大きい領域では発生件数は少ないものの非常に高い勝率を示している。つまりアマチュア集団の集合知である顧客の取引履歴情報には、大きな価格変化に対する予測力があることを確認できた。

5 まとめ

本研究では FX 業者の所持している顧客の取引履歴情報をアマチュア集団の集合知として捉え、それを用いた未来価格の予測を行った。また FX 業者の立場になり、予測を利用したカバー取引に関する新しい戦略を考案した。そして戦略の有用性を確認するために 2 つの単純な戦略を用意し、実データを用いたシミュレーションを行った。その結果、勝率は 50% を下回る結果となり予測がうまく機能しなかった。しかし、全体的

に総利益が低くなることはなく、最大ドローダウンに関してはすべての場合で良好なパフォーマンスを示した。また総利益/最大ドローダウンによりリスク当たりの収益性を評価したところ、すべての B と F において提案法の有用性を確認できた。またそれぞれの評価指数で提案法の汎化性能を調べたところ、総利益や最大ドローダウンにおいて提案法による安定性の向上を確認できた。なお、勝率が低いにもかかわらず、総利益や最大ドローダウンを向上できた理由として、大きな価格変化ほど集合知による予測が機能しやすいことを確認した。

大きな価格変化の予測が比較的容易であれば、これを考慮した新しい戦略を提案法に組み込めるかもしれない。今後は集合知を発揮するための条件として各顧客の独立性について検証し、さらに提案法の汎用性を評価するために別の期間や他通貨でもシミュレーションを行う。また説明変数や利用する予測器を変更したシミュレーションも検討し、勝率のさらなる向上を図る。

なお本研究の一部は、文科省科研費基盤研究 (C)(No.16K00320) の助成により行われました。

参考文献

- [1] 西垣通: 集合知とは何か, 中央公論新社, 2013.
- [2] 本研究では某店頭外国為替証拠金取引取扱業者との共同研究である。
- [3] 某店頭外国為替証拠金取引取扱業者より入手した。
- [4] Tomoya Suzuki and Kazuya Nakata, “Risk reduction for nonlinear prediction and its application to the surrogate data test,” *Physica D*, vol.266, pp.1–12, 2014.
- [5] Tomoya Suzuki, “Consensus Ratio and Two-Step Selection to Detect Profitable Stocks,” *IFTA JOURNAL*, pp.4–14, 2018.
- [6] Tomoya Suzuki, “Financial technical indicator based on chaotic bagging predictors for adaptive stock selection in Japanese and American markets,” *Physica A*, vol.442, pp.50–66, 2016.