

金融情報学研究会（第16回）

日時 2016年 3月 28日（土）

会場 ブルームバーグL.P.

第16回 人工知能学会 金融情報学研究会 (SIG-FIN)

2016年3月28日(月) ブルームバーグ L.P.

01. 金融商品取引のための複利型深層強化学習..... 1
松井 藤五郎, 片桐 雅浩 (中部大学)
02. SCW を用いた株価変動予測..... 8
福田 ムフタル (名古屋産業大学)
03. ダーク・プールが市場効率性と価格発見メカニズムに与える影響～人工市場モデルと数式モデルを用いたメカニズムの分析～..... 16
水田 孝信 (スパークス・アセット・マネジメント株式会社), 小杉 信太郎 (三菱 UFJ モルガン・スタンレー証券株式会社), 楠本 拓矢, 松本 渉 (野村証券株式会社), 和泉 潔 (東京大学)
04. 人工市場を用いた集団行動バイアスが市場へ与える影響の分析..... 24
王雅婷, 鳥海 不二夫 (東京大学)
05. マーケットメーカーがダーク・プールの存在する市場の効率性に与える影響: 人工市場アプローチによる分析..... 29
西岡 伸, 鳥居 拓馬, 和泉 潔 (東京大学)
06. 人工市場を用いた分散投資規制が資産価格急落時の市場に与える影響の解明..... 35
野崎 淳 (神奈川工科大学), 水田 孝信 (スパークス・アセット・マネジメント株式会社), 八木 勲 (神奈川工科大学)
07. バックテストに代わるクオンツ戦略の新しい検証方法..... 42
野村 至紀 (シンプレクス・アセット・マネジメント株式会社)
08. イジングモデルによる複数時系列の株価変動シミュレーション..... 51
高石 哲弥 (広島経済大学)
09. なぜ ロバストな アルファ (ベータ) 推定値が必要なのか —プレミアム VS あのマリーを統計的手法で超えられる?—..... 57
西山 昇 (Dragons' Desk Ltd.)
10. インターネット株式掲示板にみるカスケード効果と初期収益率..... 61
月岡 靖智 (関西学院大学)

11. 文書の分散表現と深層学習を用いた日銀政策変更の予想.....	66
塩野 剛志 (クレディ・スイス証券株式会社)	
12. Comparison among multilingual financial words using the word2vec and clustering with news resources for automatic creation of financial dictionaries.....	70
Enda Liu, Tomoki Ito, and Kiyoshi Izumi (The University of Tokyo)	

金融取引戦略獲得のための複利型深層強化学習

Compound Deep Reinforcement Learning to Acquire Trading Strategies

松井 藤五郎^{1,2*} 片桐 雅浩²

¹ 中部大学 生命健康科学部 臨床工学科 ² 中部大学 工学部 情報工学科

Abstract: 本論文では、深層強化学習を複利型に拡張した複利型深層強化学習を提案する。複利型深層強化学習は、報酬の代わりに利益率を観測し、利益率の複利効果を最大化する行動規則を学習する複利型強化学習において、行動価値関数をニューラル・ネットワークで表し、深層学習を用いて行動規則を学習する。また、金融商品（日本国債）の取引戦略の獲得に複利型深層強化学習を用いた例を示す。

1 はじめに

我々は、強化学習 (RL: reinforcement learning) における報酬 (reward) の代わりに利益率 (rate of return) を観測し、利益率の複利効果 (compound effect) を最大化する行動規則を学習する複利型強化学習を提案してきた [松井 13a, 松井 11b, Matsui 12, 松井 11a]。複利型強化学習 (compound RL) では、将来の利益率を二重指数関数を用いて割り引き、複利利益率の対数を取ることで、行動価値関数を従来の強化学習と同様の Bellman 方程式の形で表し、従来の強化学習アルゴリズムを容易に複利型強化学習アルゴリズムに拡張することを可能としている。

我々は、これまでに、強化学習と複利型強化学習を金融商品の取引戦略の獲得に応用してきた [松井 13a, 松井 11b, Matsui 09]。これらの研究では、状態変数として終値と移動標準偏差を用いており、状態変数を相対化することによって終値や移動標準偏差が大きく変動する市場でも有効な取引戦略を獲得できるようにしている。従来手法では、行動価値関数と投資比率を放射基底関数 (radial basis function) を用いて線形近似していた。しかしながら、放射基底関数を用いた線形関数近似は、状態変数を増やすと指数的に状態が複雑になり、学習が難しくなってしまうという問題があった。

深層学習 (deep learning) は、大規模で複雑なニューラル・ネットワーク (artificial neural network) を GPU の計算能力を用いて学習するものであり、画像認識の分野で特に顕著な成果を上げている。2013 年に、Mnih らによって、深層学習を用いた強化学習の手法である深層強化学習 (deep RL) [Mnih 13] が提案された。深層強化学習アルゴリズムの Deep Q-Network は、コンピューター・ゲームの画面 (画像) を入力、ゲームの得点を報酬として、高得点を取る操作方法を学習させたところ、人間よりも高得点を取ることができるようになった。これをコンピューター囲碁に適用したのが AlphaGo [Silver 16] である。2016 年 3 月、世界中にネット中継されて多くの人が注目する中、世界で最も強いプロ棋士の一人であるイ・セドルと対戦して 4 勝 1 敗で勝利したことは、1997 年に Deep Blue がチェスの世界王者であったゲーリー・カスパロフに勝利したこと [Pandolfini 97] とともに人工知能研究の歴史に残る大きな出来事となった。Deep Q-Network の大きな特徴が、コンピューター・シミュレーションによる膨大な数の反復学習を用いることによって人間以上の速さで学習すること、行動価値関数を複雑なニューラル・ネットワークで表すことによって多数の状態変数を扱えることである。

本論文では、深層強化学習を複利型に拡張した複利型深層強化学習を提案する。複利型深層強化学習は、報酬の代わりに利益率を観測し、利益率の複利効果を最大化する行動規則を学習する複利型強化学習において、行動価値関数と投資比率をニューラル・ネットワークで表し、深層学習を用いて行動規則の学習と投資比率の最適化を行う。複利型強化学習の行動価値関数と投資比率を複雑なニューラル・ネットワークで表すことによって、状態を多数の状態変数で表すことができ、より複雑な問題に適用できるようになることが期待できる。

本論文では、まず、複利型強化学習と深層強化学習について説明する。そして、深層強化学習を複利型に拡張した複利型強化学習を提案する。また、金融商品（日本国債）の取引戦略の獲得に複利型深層強化学習を用いた例を示し、最後に考察を述べる。

本論文では、まず、複利型強化学習と深層強化学習について説明する。そして、深層強化学習を複利型に拡張した複利型強化学習を提案する。また、金融商品（日本国債）の取引戦略の獲得に複利型深層強化学習を用いた例を示し、最後に考察を述べる。

* <http://とうごろう.jp>, TohgorohMatsui@tohgoroh.jp

2 複利型強化学習

2.1 複利型強化学習の枠組み

強化学習 (RL: reinforcement learning) は、試行錯誤に基づいて適切な行動規則を学習する機械学習 (machine learning) の枠組みである。エージェントは、時刻 t において状態 s_t を観測すると、行動 a_t をして実行し、その結果として報酬 r_{t+1} を得て状態 s_{t+1} に遷移する。これを繰り返しながら、割引収益 (discounted profit)

$$\begin{aligned} & r_{t+1} + \gamma r_{t+2} + \gamma^2 r_{t+3} + \dots \\ &= \sum_{k=0}^{\infty} \gamma^k r_{t+k+1} \end{aligned} \quad (1)$$

を最大化するような行動規則を学習する。ここで、 γ は将来の報酬を割り引く割引率パラメータ (discount rate) を表す。エージェントは γ が 1 に近いほど遠い将来の報酬を考慮し、 γ が 0 に近いほど近い将来の報酬しか考慮しないようになる。

複利型強化学習 (compound RL) [松井 13a, 松井 11b, Matsui 12, 松井 11a] は、報酬 r_{t+1} の代わりに利益率 R_{t+1} を観測し、割引複利利益率 (discounted compound return)

$$\begin{aligned} & (1 + R_{t+1}f)(1 + R_{t+2}f)^\gamma(1 + R_{t+3}f)^{\gamma^2} \dots \\ &= \prod_{k=0}^{\infty} (1 + R_{t+k+1}f)^{\gamma^k} \end{aligned} \quad (2)$$

の期待値を最大化するような行動規則を学習する。ここで、 R_{t+1} は時刻 t の取引の結果として時刻 $t+1$ に求めた利益率、 f は投資比率パラメータ (bet fraction) を表す。

割引複利利益率は、対数を取ることで、従来の強化学習と同じように再帰的な形で表すことができる。すなわち、行動規則 π の下での状態 s の価値 $V^\pi(s)$ と行動規則 π の下での状態 s における行動 a の価値 $Q^\pi(s, a)$ は次のように表される。

$$\begin{aligned} V^\pi(s) &= \mathbb{E}_\pi \left[\log \prod_{k=0}^{\infty} (1 + R_{t+k+1}f)^{\gamma^k} \middle| s_t = s \right] \\ &= \mathbb{E}_\pi \left[\sum_{k=0}^{\infty} \gamma^k \log(1 + R_{t+k+1}f) \middle| s_t = s \right] \\ &= \sum_{a \in \mathcal{A}} \pi(s, a) \sum_{s' \in \mathcal{S}} \mathcal{P}_{ss'}^a (R_{ss'}^a + \gamma V^\pi(s')) \end{aligned} \quad (3)$$

$$\begin{aligned} Q^\pi(s, a) &= \mathbb{E}_\pi \left[\log \prod_{k=0}^{\infty} (1 + R_{t+k+1}f)^{\gamma^k} \middle| s_t = s, a_t = a \right] \\ &= \mathbb{E}_\pi \left[\sum_{k=0}^{\infty} \gamma^k \log(1 + R_{t+k+1}f) \middle| s_t = s, a_t = a \right] \\ &= \sum_{s' \in \mathcal{S}} \mathcal{P}_{ss'}^a (R_{ss'}^a + \gamma V^\pi(s')) \end{aligned} \quad (4)$$

ここで、 $\pi(s, a)$ は行動規則 π の下で状態 s において行動 a が選択される確率 (行動選択確率)、 $\mathcal{P}_{ss'}^a$ は状態 s において行動 a を行ったときに次の状態が s' になる確率 (状態遷移確率)、 $R_{ss'}^a$ は状態 s において行動 a を行って次の状態が s' になったときに得られるグロス利益率 (利益率に 1 を加えたもの) の対数 $\log(1 + Rf)$ の期待値を表す。複利型強化学習では、すべての s, a に対してこの $Q^\pi(s, a)$ を最大化するような行動規則 π を学習する。

2.2 投資比率の最適化

複利型強化学習では、総資産のうち投資する資産の割合を表す投資比率パラメータ (bet fraction) f が導入されており、投資比率によって獲得できる複利利益率が決まる。

宝くじなど、利益率の確率分布が既知の場合には、複利利益率の期待値を最大化する投資比率を解析的に求めることができる。これをケリー基準 [Kelly, Jr. 56] という。ファイナンスの分野では、投資比率を求める方法として Vince が提案したオプティマル f (optimal f) [Vince 90a, Vince 90b] と呼ばれる手法が知られているが、オプティマル f はケリー基準、つまり複利利益率の期待値を最大化する最適な投資比率を求めることができないことを Vince 自身が認めている [Vince 11]。

そこで、複利型強化学習では、最適化手法の一つであるオンライン勾配法 (online gradient method) を用いて、投資比率を最適化する [松井 13b, 羽根田 16]。リターン R_{t+1} を観測すると、投資比率 f を次のように更新する。

$$f(s_t, a_t) \leftarrow f(s_t, a_t) + \eta_t \frac{R_{t+1}}{1 + R_{t+1}f(s_t, a_t)} \quad (5)$$

$$\eta_t = \left(\frac{\eta_0}{\sqrt{t}} \right)^k \quad (6)$$

ここで、 $0 \leq \eta_t \leq 1$ は投資比率の学習率パラメータ (learning rate)、 η_0 は初期学習率 (initial learning rate)、 k は $0 < f_{t+1}(s_t, a_t)$ となる最小の正の整数である。

利益率が $R_{t+1} = -1$ になると、投資比率が $f = 1$ だと $\log(1 + R_{t+1}f) = \log 0 = -\infty$ となり、割引複利利益率の期待値を求めることができない。そこで、ギャン

ブルなど、 $R_{t+1} = -1$ となる可能性がゼロでないときは $f < 1$ とする。

その一方で、利益率の絶対値が小さいとき（利益率がゼロに近いとき）は、投資比率を大きくしてもこの問題は生じない。外国為替証拠金取引（FX）では、レバレッジ（leverage）をかけて預け入れた証拠金の一定倍数まで取引することができる。複利型強化学習においても、このような状況では、レバレッジをかけて取引を行っても問題はなく、また、オンライン勾配法を用いてレバレッジをかけた最大投資可能額に対する最適な投資比率を求めることができる [塚本 16]。

2.3 複利型 Q 学習

従来の Q 学習では、時刻 t での状態 s_t において行動 a_t を取り、その結果として報酬 r_{t+1} を得て状態 s_{t+1} に遷移したとき、以下の式によって Q 値を更新する。

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha \left(r_{t+1} + \gamma \max_{a'} Q(s_{t+1}, a') - Q(s_t, a_t) \right) \quad (7)$$

ここで、 α は Q の学習率を表すパラメータである。

複利型 Q 学習では、 s_t で a_t を取り、その結果として利益率 R_{t+1} をえて s_{t+1} に遷移したとき、Q 値を次のように更新する。

$$r \leftarrow \log(1 + R_{t+1}f(s_t, a_t)) \quad (8)$$

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha \left(r + \gamma \max_{a'} Q(s_{t+1}, a') - Q(s_t, a_t) \right) \quad (9)$$

複利型 Q 学習は、Q 学習の報酬 r_{t+1} をグロス利益率の対数 $\log(1 + R_{t+1}f(s_t, a_t))$ に置き換え、オンライン勾配法による投資比率の最適化を加えたものである。Algorithm 1 に、複利型 Q 学習のアルゴリズムを示す。

2.4 取引戦略の獲得

株価など金融商品の価格は大きく変動するため、そのまま状態変数として用いると未知の状態に陥りやすい。たとえば、ある株式を対象としているときに、その株価が上場来高値を更新している状態では、株価をそのまま状態変数として用いていると、未だかつて体験したことのない状態であるため、学習が行われていない状況で行動しなければならなくなってしまう。

そこで、状態変数を、直近の値と比較した相対的な値として正規化することによって、状態変数の値が大きく異なる場合でも学習した行動規則を利用できるようにす

る。具体的には、移動平均 (moving average) および移動標準偏差 (moving standard deviation) の算出期間を k とし、以下のようにして相対化 (relativization) する [Matsui 09]。

$$x_{i,t} = \frac{v_{i,t} - \mu_{t,k}}{4\sigma_{t,k}} \quad (10)$$

ここで、 $v_{i,t}$ は時刻 t における i 番目の状態変数の値、 $\mu_{t,k}$ は時刻 t の直近 k 個のデータから求めた移動平均、 $\sigma_{t,k}$ は同じく移動標準偏差を表す。

これまでの研究では、終値を相対化した相対終値 (RCP: relative closing price) と移動標準偏差を相対化した相対移動標準偏差 (RMSD: relative moving standard deviation) を状態変数として用いている。株式を対象とした取引の場合、RCP が正のときは現在の株価が移動平均株価より大きい、すなわち、株価が上昇していることを表している。RMSD が正のときは現在の標準偏差が移動平均標準偏差より大きい、すなわち、株価の変動が大きくなっていることを表している。

エージェントの行動は買い (buy) と売り (sell) の 2 種類である。金融商品を購入している状態をロング・ポジション、金融商品を信用売りしている状態をショート・ポジションという。エージェントは、複利型強化学習によって学習された取引戦略によって行動を選択し、オンライン勾配法によって学習された投資比率 f によってポジションの大きさを調整する。

なお、本研究では、金融市場に関する状態変数はエージェントの行動に依存しないと仮定している。たとえば、株取引の場合には、エージェントがどちらの行動を選んでも、株価には影響しない。

3 深層強化学習

深層強化学習 (deep RL) [Mnih 13, Silver 16] は、強化学習における価値関数 (value function) Q をニューラル・ネットワーク (artificial neural network) で表し、深層学習 (deep learning) を用いて Q を学習するものである。

図 1 に、Deep Q-Network のニューラル・ネットワークを示す。状態 s が m 次元の状態変数ベクトル $\mathbf{x} = (x_1, x_2, \dots, x_m)$ で表されるとき、入力層には $m+1$ 個のユニットが配置され、 x_1 から x_m までの状態変数と行動 a が入力される。出力層にはユニットが一つだけ配置され、状態 s における行動 a の価値 $Q(\mathbf{x}, a)$ が出力される。

Deep Q-Network の学習アルゴリズムを Algorithm 2 に示す。従来の Q 学習では 1 ステップごとに

Algorithm 1 複利型 Q 学習アルゴリズム

入力: 割引率 γ , 行動価値学習率 α , 初期投資比率 f_0 , 初期投資比率学習率 η_0

```

for all  $s, a$  do
   $Q(s, a)$  を任意に初期化
   $f(s, a) \leftarrow f_0$ 
end for
loop (各エピソードに対して繰り返し)
   $s$  を初期化
  repeat (エピソードの各ステップに対して繰り返し)
     $Q$  から導かれる行動規則 (行動選択確率) に従って  $s$  での行動  $a$  を選択
    行動  $a$  を実行し、利益率  $R$  と次の状態  $s'$  を観測
     $Q(s, a) \leftarrow Q(s, a) + \alpha \left( \log(1 + Rf(s, a)) + \gamma \max_{a'} Q(s', a') - Q(s, a) \right)$ 
     $\eta \leftarrow 1, f \leftarrow f(s, a), \Delta f \leftarrow \frac{R}{1 + Rf}$ 
    repeat
       $\eta \leftarrow \frac{\eta_0}{\sqrt{t}} \eta, f' \leftarrow f + \eta \Delta f$ 
    until  $f' > 0$ 
     $f(s, a) \leftarrow f', s \leftarrow s'$ 
  until  $s$  が終端状態ならば繰り返しを終了
end loop
  
```

Algorithm 2 Deep Q-Network 学習アルゴリズム

入力: 割引率 γ , 行動価値学習率 α

Q を表すニューラル・ネットワークを任意に初期化

for $i = 1$ to N **do**

Q から導かれる行動規則に従ってしばらくの間行動し、状態変数ベクトル \mathbf{x} , 行動 a , 報酬 r , 次の状態の状態変数ベクトル \mathbf{x}' の組を収集する

収集した $\langle \mathbf{x}, a, r, \mathbf{x}' \rangle$ の集合からランダム・サンプリングによって M 個を取り出す

for $j = 1$ to M **do**

$$q_j \leftarrow Q(\mathbf{x}_j, a_j) + \alpha \left(r_j + \gamma \max_{a'} Q(\mathbf{x}'_j, a') - Q(\mathbf{x}_j, a_j) \right)$$

end for

\mathbf{x}_j と a_j を入力、 q_j を出力とした M 個 ($j = 1, \dots, M$) の訓練データを用いて Q を表すニューラル・ネットワークを更新する

end for




図1 Deep Q-Network

かれる行動規則に従って M ステップ以上行動し、状態 s_t を表す状態変数ベクトル \mathbf{x}_t , 行動 a_t , 報酬 r_{t+1} , 次の状態 s_{t+1} の状態変数ベクトル \mathbf{x}_{t+1} の組を収集する。収集した $\langle \mathbf{x}_t, a_t, r_{t+1}, \mathbf{x}_{t+1} \rangle$ の集合から、ランダム・サンプリングによって M 個を取り出す。取り出した M 個のデータのそれぞれに対し、以下の式によって \mathbf{x}_t と a_t を Deep Q-Network へ入力したときの望ましい出力値 q_t を求める。

$$q_t \leftarrow Q(\mathbf{x}_t, a_t) + \alpha \left(r_{t+1} + \gamma \max_{a'} Q(\mathbf{x}_{t+1}, a') - Q(\mathbf{x}_t, a_t) \right) \quad (11)$$

これらの M 個のデータを訓練データとして Deep Q-Network を更新する。これを N 回繰り返す。

Deep Q-Network のランダム・サンプリングは、深層

Q 値を更新して学習するが、Deep Q-Network では、1 ステップごとの学習は行わず、 M ステップ分の更新をまとめて行う。Deep Q-Network を固定して Q から導




図2 複利型 Deep Q-Network

学習で大きな問題となる過学習 (overfitting) への対策となっている。すべてのステップで学習せずに、ランダムに選択されたステップのみで学習することによって、特定の状況へ過度にフィットしないようになっている。これは、アンサンブル学習 (ensemble learning) のバギング (bagging) が過学習対策として用いられるのと同じ仕組みである。

4 複利型深層強化学習

4.1 仕組みとアルゴリズム

複利型深層強化学習 (compound deep RL) は、深層強化学習を複利型に拡張したものである。図2に、Deep Q-Network を複利型に拡張した複利型 Deep Q-Network のニューラル・ネットワークを示す。複利型 Deep Q-Network では、行動価値 Q に加えて、投資比率 f を出力する。

複利型 Deep Q-Network の学習アルゴリズムは、Deep Q-Network 学習アルゴリズムを複利型に拡張したものである。複利型 Deep Q-Network の学習アルゴリズムを Algorithm 3 に示す。

複利型強化学習は、従来の強化学習における報酬 r の代わりに利益率 R を受け取り、更新式の報酬 r をグロス利益率の対数 $\log(1 + Rf)$ に置き換えたものである。複利型深層強化学習も、同様に、深層強化学習における報酬 r の代わりに利益率 R を受け取る。複利型 Deep Q-Network では、 $\langle \mathbf{x}_t, a_t, R_{t+1}, \mathbf{x}_{t+1} \rangle$ を収集し、そこからランダム・サンプリングによって Deep Q-Network を更新するための訓練データを作成する。このとき、 \mathbf{x}_t と a_t を Deep Q-Network へ入力したときの望ましい出力値 q_t は、以下のように求める。

$$r \leftarrow \log(1 + R_{t+1}f) \quad (12)$$

$$q_t \leftarrow Q(\mathbf{x}_t, a_t) + \alpha \left(r + \gamma \max_{a'} Q(\mathbf{x}_{t+1}, a') - Q(\mathbf{x}_t, a_t) \right) \quad (13)$$

複利型強化学習では、投資比率 f が導入されている。複利型深層強化学習では、ニューラル・ネットワークの出力層に投資比率 f を加え、行動価値 Q とともに出力する。 \mathbf{x}_t と a_t を複利型 Deep Q-Network へ入力したときの望ましい出力値 f_t は、以下のように求める。

$$f_t \leftarrow f(\mathbf{x}_t, a_t) + \eta_t \frac{R_{t+1}}{1 + R_{t+1}f(\mathbf{x}_t, a_t)} \quad (14)$$

$$\eta_t = \left(\frac{\eta_0}{\sqrt{iM}} \right)^k \quad (15)$$

ここで、 $0 \leq \eta_t \leq 1$ は投資比率の学習率パラメーター (learning rate)、 η_0 は初期学習率 (initial learning rate)、 i は繰り返し回数、 M はランダム・サンプリングのサンプル数、 k は $f_t > 0$ となる最小の正の整数である。

4.2 実装

本研究では、深層学習ライブラリーの Deeplearning4j (DL4J) に、複利型強化学習のモジュールを作成して組み込むことで、複利型 Deep Q-Network のプログラムを実装した。

本論文における金融商品取引では、状態変数の値を過去の価格データだけから求められるため、任意の時点から行動を始めることができる。そこで、しばらくの間行動して $\langle \mathbf{x}_t, a_t, R_{t+1}, \mathbf{x}_{t+1} \rangle$ を収集し、そこからランダム・サンプリングを行う代わりに、取引時刻をランダム・サンプリングによって選択し、取引を行うことによって $\langle \mathbf{x}_t, a_t, R_{t+1}, \mathbf{x}_{t+1} \rangle$ を収集する。

そこで、DL4J に以下の5つのモジュールを追加した。

1. ランダム・サンプリング
2. Q 値推定
3. 行動選択
4. 利益率計算
5. 更新後 Q 値計算

まず、(1) ランダム・サンプリングによって、全期間から M 個の取引時刻を選択する。選択したデータ $\langle \mathbf{x}_j, a_j, R_j, \mathbf{x}'_j \rangle$ のそれぞれに対して、(2) 行動 (買いまたは売り) ごとに、学習中のニューラル・ネットワークに状態変数 \mathbf{x}_j と行動を入力して Q 値と投資比率 f を推定し、(3) 推定した Q 値に基づいて、 ϵ -グリーディー選択を用いて行動 a_j を選択、(4) a_j を取ったときの利益率 R_j を求め、(5) Q 値推定モジュールを用いて次の状態での行動価値を推定し、式 (12)–(15) を用いて Q 値と投資比

Algorithm 3 複利型 Deep Q-Network 学習アルゴリズム

入力: 割引率 γ , 強化学習率 α , 投資比率学習率 η_0

Q と f を表すニューラル・ネットワークを任意に初期化

for $i = 1$ to N do

Q から導かれる行動規則に従ってしばらくの間行動し、状態変数ベクトル \mathbf{x} , 行動 a , 利益率 R , 次の状態の状態変数ベクトル \mathbf{x}' の組を収集する

収集した $\langle \mathbf{x}, a, R, \mathbf{x}' \rangle$ の集合からランダム・サンプリングによって M 個を取り出す

for $j = 1$ to M do

$$q_j \leftarrow Q(\mathbf{x}_j, a_j) + \alpha \left(\log(1 + R_j f) + \gamma \max_{a'} Q(\mathbf{x}'_j, a') - Q(\mathbf{x}_j, a_j) \right)$$

$$\eta \leftarrow 1, f \leftarrow f(\mathbf{x}_j, a_j), \Delta f = \frac{R_j}{1 + R_j f}$$

repeat

$$\eta \leftarrow \frac{\eta_0}{\sqrt{iM}} \eta, f' \leftarrow f + \eta \Delta f$$

until $f' > 0$

$$f_j \leftarrow f'$$

end for

\mathbf{x}_j と a_j を入力、 q_j と f_j を出力とした M 個 ($j = 1, \dots, M$) の訓練データを用いて Q と f を表すニューラル・ネットワークを更新する

end for




図3 残存期間10年日本国債金利と $\pm 4\sigma$ のボリンジャー・バンド

率の望ましい値 q_j, f_j を求める。最後に、DL4J の機能を用いて、 M 個の訓練データを与えてニューラル・ネットワークを更新する。これを N 回繰り返す。

5 実験結果

提案手法の有効性を確認するために、残存期間10年の日本国債の週次取引を対象として実験を行った。取引の期間は、2004年から2007年の4年間とした。図3に、対象期間の金利の推移と $\pm 4\sigma$ のボリンジャー・バンドを示す。この期間には計208週あり、利益率を計算するため、最後の週を除いた207週を対象とした。移動平均と移動標準偏差の算出期間は、従来研究と同じ14週とした。

複利型 Deep Q-Network と従来の Deep Q-Network で用いるニューラル・ネットワークは、中間層を1つ、ユニット数は20とした。重みの初期値は Xavier を用いて確率的に決定し、入力層から中間層への活性化関数はランプ関数 (ReLU)、中間層から出力層への活性化関数は線形結合 (単純パーセプトロン) とした。

強化学習の行動選択には $\epsilon = 0.2$ の ϵ -グリーディー選択を用い、行動価値の学習率は $\alpha = 0.2$ 、割引率は $\gamma = 0$ とした。ランダム・サンプリングのサンプル数は $M = 100$ とし、繰り返し回数を $N = 10,000$ とした。また、今回の実験では、複利型 Deep Q-Network の投資比率 f の最適化は行わず、 $f = 1$ に固定した。

繰り返し1回ごとに、すなわち、通常が強化学習100ステップ分の学習を行うごとに、学習した Q を用いて全期間で取引を行い、その年平均利益率を求め、繰り返し100回ごとに年平均利益率の平均を求めた。結果を図4に示す。最後の100回の年平均利益率の平均値は複利型 Deep Q-Network が2.12%、Deep Q-Network が2.08%であった。t検定によって平均の差を検定したところ、差の平均値は0.365、標準偏差は0.371であり、差の95%信頼区間の下限が0.0291、上限が0.0439であることから、有意水準5%で優位な差があることが確認された。また、自由度99でt統計量が9.83であったことから、有意水準0.1%でも有意な差があった。




図4 実験結果

6 考察とまとめ

本論文では、深層強化学習を複利型に拡張した複利型深層強化学習を提案した。深層強化学習は、囲碁に応用した AlphaGo が世界で最も強い棋士の一人に勝利するなど、従来は複雑で難しいと考えられていた問題にも適用可能であることが示されており、これを複利型に拡張した複利型深層強化学習は、複雑な環境でも複利利益率を最大化することが期待できる。本論文では、深層学習ライブラリーの DeepLearning4j (DL4J) に複利型強化学習のモジュールを作成して追加することで、複利型 Deep Q-Network を実装した。また、日本国債の週次取引を対象とした実験により、複利型深層強化学習が取引戦略を学習できることを確認した。

今後の課題はまだ多く残っている。まず、深層強化学習の特徴の一つは、複雑なニューラル・ネットワークを用いて Q 関数を表すことによって、多数の状態変数を扱うことができることである。本論文では、従来手法と同じ、相対終値と相対移動標準偏差の二つしか状態変数を用いていない。多数の状態変数を用いることによって優れた取引戦略の獲得ができるか、検証が必要である。

また、本論文の実験では、投資比率を $f = 1$ にして実験を行った。本論文で提案した投資比率 f をニューラル・ネットワークで表して投資比率を最適化することについての有効性はまだ確認されていない。これについても、検証が必要である。

今後、複数の金融商品を対象とした実験を行い、これらの有効性を検証していきたい。

参考文献

[Kelly, Jr. 56] Kelly, Jr., J. L.: A new interpretation of information rate, *Bell System Technical Journal*, 35:917–926

(1956)

[Matsui 09] Matsui, T., Goto, T., and Izumi, K.: Acquiring a government bond trading strategy using reinforcement learning, *JACIII*, 13(6):691–696 (2009)

[Matsui 12] Matsui, T., Goto, T., et al.: Compound Reinforcement Learning: Theory and An Application to Finance, in *European Workshop on Reinforcement Learning 9 (EWRL 2011)*, LNCS 7188:321–332 (2012)

[Mnih 13] Mnih, V., Kavukcuoglu, K., et al.: Playing Atari with Deep Reinforcement Learning, in *NIPS Deep Learning Workshop* (2013)

[Pandolfini 97] Pandolfini, B.: *KASPAROV AND DEEP BLUE*, Simon & Schuster (1997), 鈴木知道 訳, ディープブルー vs. カスパロフ, 河出書房新社 (1998)

[Silver 16] Silver, D., Huang, A., et al.: Mastering the game of Go with deep neural networks and tree search, *Nature*, 529:484–489 (2016)

[Vince 90a] Vince, R.: Find your optimal f , *Technical Analysis of Stock & Commodities*, 8(12):476–477 (1990)

[Vince 90b] Vince, R.: *Portfolio management formulas: Mathematical trading methods for the futures, options, and stock markets*, Wiley (1990), 長尾 慎太郎 訳, 投資家のためのマネーマネジメント—資産を最大限に増やすオプティマル f , パン・ローリング (2005)

[Vince 11] Vince, R.: Optimal f and the Kelly Criterion, *IFTA Journal*, 21–28 (2011)

[塚本 16] 塚本 智大, 松井 藤五郎: レバレッジを用いた複利型強化学習, 第 78 回情報処理学会全国大会 (IPSJ 78), 3P3-05 (2016)

[羽根田 16] 羽根田 卓哉, 松井 藤五郎: 複利型強化学習における投資比率学習法の改善, 第 78 回情報処理学会全国大会 (IPSJ 78), 3P3-06 (2016)

[松井 11a] 松井 藤五郎: 複利型強化学習, *人工知能学会論文誌*, 26(2):330–334 (2011)

[松井 11b] 松井 藤五郎, 後藤 卓, 和泉 潔, 陳 ユ: 複利型強化学習の枠組みと応用, *情報処理学会論文誌*, 52(12):3300–3308 (2011)

[松井 13a] 松井 藤五郎: 複利型強化学習—強化学習のファイナンスへの応用—, *計測と制御*, 52(11):1022–1027 (2013)

[松井 13b] 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*, 28(3):267–272 (2013)

SCWを用いた株価変動予測

Predicting Stock Fluctuations using Soft Confidence-Weighted Learning

福田 ムフタル^{1*} Muhtar Fukuda¹

¹ 名古屋産業大学環境情報ビジネス学部

¹ Faculty of Environmental and Information Studies, Nagoya Sangyo University

Abstract: Stock price prediction is a long-time and challenging topic in financial forecasts. Although stock markets are affected by many uncertain factors, numerous effectual approaches have been proposed to predict financial market trends using machine learning algorithms, such as Support Vector Machine (SVM) and Deep Belief Network (DBN). In this research, we propose a new approach to predict short-term stock fluctuations using Soft Confidence-Weighted (SCW) Learning. The proposed method not only predicts stock trends, but also gives a quantitative measure for the stock fluctuations. We consider RoC time series of a related stock class as inputs, fluctuate up and down of a target stock as outputs, to train the prediction model with SCW. Some experimental results show that the approach is useful for practical purposes.

1 はじめに

株式は多くの投資家にとって魅力的な投資対象であり、企業にとっては資金調達の一手段である。そのことから常に需要と供給が発生し、そのバランスによって市場価格が形成され、またはその価格で取引されると考えられており、経済学の理論や豊富な取引経験を持ったプロの投資家たちが様々な方法で分析を行いながら将来の経済動向を予測し、投資を行ってきた。

しかし、IT技術を基盤とした株式投資環境の発展、魅力的な投資商品の拡充、個人投資家を含めた市場参加者の拡大、マーケットのグローバル化、更にはSNS等を手段としたソーシャルメディアネットワークの普及により、株価形成に影響を与える要素が複雑化し、市場動向を伝統的な経済学や金融工学の理論だけでは説明できないケースが増え、投資パフォーマンスの予測が一層困難になってきた。そのような状況から、経験の浅い個人投資家に限らず、プロの機関投資家にとっても利益の最大化とリスクの最小化に役立つようなツールや方法の必要性が高まってきた。

また、人工知能の分野では前述の状況と並行して Deep Learning (DL)[1] に代表される先進的な機械学習モデルが考案され、大規模なニューラルネットワークを構築し、様々なビッグデータに対して機械学習を行い、全パラメータを最適化するというパラダイムシフトが起

きた。DLの金融データへの応用例として Deep Belief Network(DBN)[8]を用いた為替レート変動の予測 [2] や上場企業倒産の予測 [3] 等の研究が報告され、その有効性が示されている。また、もう一つの有力な機械学習モデルである Support Vector Machine (SVM)[5]を用いた株価予測に関する研究も数多く発表され [6, 7]、高精度のトレンド予測を実現したものもある。SVMはカーネルトリック [4] による非線形の識別関数を構成できるように拡張された学習モデルであり、現在知られている多くの手法の中でも最も認識性能の高いモデルの一つとされている。

しかし、多階層のネットワーク構造である DBN[8]を用いて金融時系列データの学習と予測を行う場合、その学習(訓練)に大変な時間がかかる。金融時系列データには時間的従属関係があり、訓練期間を常に最新のものに更新し、再学習を繰り返す必要がある。この問題に関しては自己組織化マップ(SOM)を用いて訓練期間全体から部分的なデータを取り出し、その部分的なデータのみで学習を行うことで学習の効率化と学習時間の低減を試みた研究 [9] があり、一定の改善があったと考えられるが、分単位の時系列データで学習と予測を行うことを考えた場合、更に学習時間の短縮が必要である。

一方、SVM[5]を用いて金融時系列データの学習と予測を行う場合、その正解率が訓練データのサイズと属性値(feature)の選択に左右される場合が大きい [7]。また、金融時系列データは非線形であり、SVMモデルの予測正解率を上げるためには、非線形カーネルを使用する必要がある。非線形カーネルには複数のパラメー

*連絡先：名古屋産業大学環境情報ビジネス学部
〒488-8711 愛知県尾張旭市新居町の田 3255-5
E-mail: fukuda@nagoya-su.ac.jp

タがあり、SVMの振る舞いによりかなり影響を及ぼすため、その調整を慎重にかつ時間をかけて行わなければならない。訓練期間を常に更新する必要性のある機械学習の場合には問題になる。

更に、以上の各モデルを含め、従来の予測モデルの殆どは一日後の株価の方向性一致率に重点をおいており、ある銘柄の次の日の株価を「上がる」と予測し、実際の株価が例え0.01%でも上がった場合、それが正解とされる。それは論理的には正解となっても、実際の投資目的には不十分である。株価予測の場合、株価が上がるか下がるかだけではなく、その騰落の程度を定量的に示すことがより重要である。買って売ってもコストに見合ったリターンが望めない場合は何もせず、一定以上のリターンが望めるタイミングで売買を行うのが実用的である。

本研究では、オンライン学習の一つである Soft Confidence-Weighted Learning (SCW)[10] を利用し、株価が上がるか下がるかの方向性だけではなく、株式の売買タイミングにも重点をおいた株価の値動きを予測する手法を提案する。

2 基本的な考え方

本研究では、以下の6つの考え方に基づいた株価予測を行う。

1) 予測できる可能性が高く、リスクが低い銘柄だけを予測の対象にする。今回は、予測対象として日経平均株価指数 [11] を考える。個別の銘柄の値動きはいろいろな要素の影響を受ける。次の日に上がると予測して株を購入し、次の市場が始まる前に悪材料が出た場合、予測が大きく外れることになる。格付け会社によってレーティングが変更されたり、目標株価がわずかに変更されただけで株価が動き、関連銘柄にも影響が出る場合がある。その点で日経平均株価指数は比較的に安定しており、予測しやすい。また、日経平均株価指数に一对一に連動するETFが幾つかあり、流動性が非常に高く、いつでもどこでも売買できる。

2) 一つの銘柄の株価は独立に動くことは殆どなく、複数の銘柄と直接または間接的に影響しあって相関的に動くと考え。従って、一つの銘柄の値動きを予測するためには関連性の高い複数の銘柄の時系列データの組み合わせを入力データとし、その関連銘柄群を一定の手順（後述）に基づいて常に機械的に選択し直す。その銘柄群を「ベース銘柄集」と呼ぶことにする。

周知の通り、株価の値動きは、需給、株価材料、投資家心理、為替、経済政策、国内外の政治経済状況、地政学、影響力の高い人物の発言、マスメディアなど様々な要因の影響を受ける。しかし、セクション1で述べたように、現在のマーケットを取り巻く環境は劇的に変化し

ており、何かが発生したら瞬時に株価の値動きに反映されるし、一つの銘柄の値動きに影響を及ぼす銘柄群も部分的に入れ替わっているはずである。

3) 学習期間 (図1の(c)) として予測ポイント (図1の(b)) から数日間離れた学習起点 (図1の(a)) より過去10年間前後の株価時系列データを使用するが、常に最新のものになるように学習起点をずらし続ける。ベース銘柄集と学習期間を常に更新し続けることにより、他の全ての株価変動要因が株価時系列データに反映されている状態が維持される。




図1: ウィンドウ・学習起点・予測ポイント

4) 本研究では、次の日の株価の値動きではなく、次の日から数日間のウィンドウ内の値動きを学習や予測のターゲットにする。このウィンドウをターゲットウィンドウと呼び、学習ターゲットウィンドウ (図1の(d)) と予測ターゲットウィンドウ (図1の(e)) の二つに分けて考える。日数がターゲットウィンドウのサイズになる。ここでもやはり予測しやすいターゲットウィンドウサイズを考える。

5) 入力データに関してある時点から見た過去一定期間内の株価のトリプルボトムとトリプルトップの変動率を入力データの属性値 (feature) とし、その期間を属性ウィンドウ (図1の(f)) と呼ぶ。そして、予測対象銘柄の値動きと相関性の高い複数銘柄の属性値の組み合わせを一次的な入力データとし、学習期間の入力データを行に持つ行列 X^0 を作り、

$$X^0 = U\Sigma V^t \quad (1)$$

のように特異値分解し、行列 X^0V の各行を最終的な入力とする。予測ポイント t_0 の予測を行う時の一次的な入力データ $x_{t_0}^0$ に関して、 $x_{t_0}^0 = x_{t_0}^0 V$ を最終的な入力とする。

6) 本研究では、売買タイミングの割り出しにも重点をおいた予測を行う。騰落の程度を定量的に測る指標として「騰落強度」を導入する。「騰落強度」が大きければ大きいほど、売買タイミングに近付いたと判断する。

SCWを含めたオンライン学習では、入力 $x_t \in \mathcal{R}^d$ と機械学習によって更新される重み $w \in \mathcal{R}^d$ に対して、

$$\hat{y}_t = \text{sgn}(x_t \cdot w), \hat{y}_t \in \{+1, -1\} \quad (2)$$

でもって入力 x_t が属するクラスを予測する。

本研究では、全ての入力が d 次元空間の点であり、それらの点が法線ベクトル w を持つ超平面によって二つに分離され、点と分離超平面との距離が大きければ大きいほどそのクラスへの属性が強いと見做し、その距離(符号付き)を「騰落強度」とする。即ち、騰落強度 FS (Fluctuation Strength) を次のように定義する。

$$FS = \frac{x_t \cdot w}{|w|} \quad (3)$$

ここで、 $|FS|$ は騰落の強さ、 $\text{sgn}(FS)$ は上がるか下がるかの方向になる。しかし、騰落強度が最も大きい場合変動率が一番大きくなるという訳ではなく、その傾向が強いことを表す量になる。本研究では、その妥当性を実験によって検証する。

3 オンライン学習と SCW

オンライン学習は機械学習モデルにおける学習アルゴリズムの1つであり、入力データを1つずつ読み込んでモデルの更新を繰り返すことで学習を行い、時系列データの学習によく利用されている。オンライン学習では、入力の時系列データ $x_t \in \mathcal{R}^d$, $t = 1, 2, \dots, T$ に対して、そのラベル $\hat{y}_t \in \{+1, -1\}$ を予測し、正解ラベル $y_t \in \{+1, -1\}$ との差(損失)を損失関数 $l((x_t, y_t), \hat{y}_t)$ で計算し、その損失が一定の基準によって学習モデルの重みの更新に利用され、累積損失 $\sum_{t=1}^T l((x_t, y_t), \hat{y}_t)$ を最小化することで、学習が終了する。

オンライン機械学習には、他にも State-of-the-art の学習モデルとして CW[13], AROW[14], NAROW[15] などがあり、超空間上の点と平面の距離を騰落強度とする本研究の目的には合致するが、次の五つの理由から SCW[10] を利用することにした。1) 他のアルゴリズムの長所を持ちつつ、ノイズや直前のデータへの脆弱性が緩和されている。本研究では、直前のデータで学習を行うし、直後のデータの予測も行う。2) 他のアルゴリズムと同様 SCW にもいくつかのパラメータがあるが、パラメータを適当に調整しても識別率に殆ど影響がない。3) 他のアルゴリズムよりも識別能力が高い。4) 線形分離不可の入力データにも対応可能である。5) 共分散行列の更新を高速に行うことが可能である。

SCW に関してはオリジナルの参考文献 [10] で詳しく述べられているので、ここではその概要だけを述べる。SCW では CW や AROW の CW 系と同様、重みベクトル w が平均ベクトル μ , 共分散行列 Σ のガウス分

布に従うと仮定するが、損失関数 $l^\phi(\mathcal{N}(\mu, \Sigma); (x_t, y_t))$ を独自に定義している。

$$l^\phi(\mathcal{N}(\mu, \Sigma); (x_t, y_t)) = \max(0, \phi \sqrt{x_t^\top \Sigma x_t} - y_t \mu \cdot x_t)$$

ここで、 η は $r_w \sim \mathcal{N}(\mu, \Sigma)$, $P[y_t(w \cdot x_t) \geq 0] \geq \eta$ を満たすパラメータ、 Φ^{-1} は逆累積分布関数、 $\phi = \Phi^{-1}(\eta)$ である。

```

1 パラメータ:  $C > 0, \eta > 0$ 
2 初期化:  $\mu_1 = (0, 0, \dots, 0), \Sigma_1 = I, \phi = \Phi^{-1}(\eta),$ 
    $\psi = 1 + \frac{\phi^2}{2}, \xi = 1 + \phi^2$ 
3 for  $t = 1, 2, \dots, T$  do
4    $x_t \in \mathcal{R}^d$  を受け取る
5   ラベル  $\hat{y}_t$  を予測する:  $\hat{y}_t = \text{sgn}(x_t \cdot \mu_t)$ 
6   真ラベル  $y_t \in \{+1, -1\}$  の提示と損失の計算:
    $l_t = \max(0, \phi \sqrt{x_t^\top \Sigma_t x_t} - y_t \hat{y}_t)$ 
7   if  $l_t > 0$  then
8      $\mu_t$  と  $\Sigma_t$  の更新を行う:
      $\mu_{t+1} = \mu_t + \alpha_t y_t \Sigma_t x_t,$ 
      $\Sigma_{t+1} = \Sigma_t - \beta_t \Sigma_t x_t^\top x_t \Sigma_t$ 
9   end
10 end
```

Algorithm 1: SCW の学習アルゴリズム

SCW の学習アルゴリズムにおける α_t と β_t は更新係数と呼ばれ、式 (4) と (5) によって計算される。

$$\alpha_t = \min\{C, \max\{0, \frac{1}{v_t \xi} (-m_t \psi + \sqrt{m_t^2 \frac{\phi^4}{4} + v_t \phi^2 \xi})\}\} \quad (4)$$

$$\beta_t = \frac{\alpha_t \phi}{\sqrt{u_t + v_t \alpha_t \phi}} \quad (5)$$

ここで、

$$u_t = \frac{1}{4} (-\alpha_t v_t \phi + \sqrt{\alpha_t^2 v_t^2 \phi^2 + 2v_t})^2$$

$$v_t = x_t^\top \Sigma_t x_t, m_t = y_t (\mu \cdot x_t)$$

SCW では、 α_t の計算式が2種類あり、その種類によって“SCW-I”, “SCW-II”と呼ばれており、本研究では前者のほうを用いる。

実際の学習では、Step 3~9 を複数回繰り返し、最終的な μ_t をモデルの重み w として使用する。パラメータ $C (> 0)$ と $\eta (> 0)$ の値は、取り扱う時系列データ、その属性値、学習期間、学習ウィンドウやターゲットウィンドウのサイズなどによって調整が必要であると思われるが、本研究では一度学習ウィンドウとターゲットウィンドウのサイズを固定し、 C に関して $\{2^{-4}, 2^{-3}, \dots, 2^3, 2^4\}$, η に関しては $\{0.50, 0.55, \dots, 0.90, 0.95\}$ でのクロスバリデーション実験を行って C と η の値を決定した後、学習ウィンドウとターゲットウィンドウのサイズを適当に変更して実験を行ったところ、パラメータ値をそれぞれ決定して学習させた場合と一つに固定して学習さ

せた場合とで、その認識率の差が1%未満、繰り返し回数も数パーセント未満に抑えられており、固定のパラメータ値を使用する。そうすることで、学習時間を大幅に抑えることができる。今回のクロスバリデーション実験で決定したパラメータ値は $C = 0.125$, $\eta = 0.7$ である。

SCW を利用したことで学習時間を大幅に低減できるメリットはもう一つある。SCW の学習アルゴリズムの損失関数関数 l_t の計算、及び μ_t と Σ_t の更新では、数千行 × 数千列に及ぶ共分散行列 Σ_t に関する行列計算が複数カ所あり、それにはかなりの計算時間が必要になる。しかし、CW 系の SCW では Σ_t の対角線以外の要素を常に 0 にしても認識率に大きな影響がないことが知られており [16]、本研究の実験でも確認しているので、ベクトルの内積計算だけで済ませることができる。

4 提案手法による予測実験

株価の値動き、及び売買タイミングの予測に関する基本的な考え方は2で述べた通りである。

このセクションでは、まずベース銘柄集の自動選択、入力データを構成する属性値の決定、ラベル付け基準値の決定、及び入出力データの作成について述べる。それから、日経平均株価指数を対象とした予測実験を行い、株価の値動き予測に関して SCW に識別能力があることと予測ポイントの見極めに有効であることを示す。

4.1 ベース銘柄集の自動選択

一つの銘柄、日経平均株価指数のような株価指数、あるいは特定の業種に連動するように設定された Exchange Traded Fund (ETF) などは独立に動くことは殆どなく、その市場価格が複数の銘柄と直接または間接的に影響しあって相関的に変動すると考えられる。構成銘柄リストに含まれていない場合でさえその可能性がある。従って、一つの銘柄の値動きの予測を行う場合、関連性の高い銘柄群の時系列データの組み合わせを入力データとするのが自然である。そのような銘柄郡をベース銘柄集と呼ぶ。

ベース銘柄集をどの株式市場の上場銘柄から選ぶのか、国内外から同時に選ぶのかなどを検討する必要があるが、今回は東京証券取引所で取引されている全ての銘柄をベース銘柄集の選択対象とする。

ベース銘柄集を次のような手順で選択する。まず便宜上、選択対象の全銘柄の集合を \mathcal{S} 、学習期間を T 、銘柄 $s \in \mathcal{S}$ の学習期間中の売買成立日数を T_s 、 s の最大連続売買不成立日数を N_s ($T = T_s + N_s$)、基準最低取引成立日数を T_0 、基準最大連続不成立日数を N_0 とする。

Step0 予測対象銘柄 $s_0 \in \mathcal{S}$ を一つ決定する。話を進めやすくするため、全期間中において売買不成立日のない銘柄を選ぶ。即ち、 $N_{s_0} = 0$ になるような銘柄を選ぶ。

Step1 $\mathcal{S}_1 = \{s \in \mathcal{S} \mid T_s \geq T_0, N_s \leq N_0\}$ とする。即ち、できるだけトータルで売買不成立日が少くかつ連続の売買不成立日の少ない銘柄を選ぶ。 $s \in \mathcal{S}_1$ に売買不成立がある場合、3次 Spline による補間を行う。

今回の実験で $T = 2000$, $T_0 = 1900$, $N_0 = 2$ としており、そうした場合、 $|\mathcal{S}_1|$ は 900 前後になる。

Step2 \mathcal{S}_1 から時価総額上位 $P_1\%$ の銘柄を選び、 \mathcal{S}_2 とする。 $P_1 = 80\%$ とした場合、 $|\mathcal{S}_2|$ は 720 前後になる。

Step3 \mathcal{S}_2 から平均変動率の高い上位 $P_2\%$ の銘柄を選び、 \mathcal{S}_3 とする。ある銘柄 $s \in \mathcal{S}_2$ の予測ポイントから t 日目の株価終値時系列を $p_t, t = 1, 2, \dots, T$ とした場合の s の平均変動率 $AvgRoC(s)$ を次のように定義する。

$$AvgRoC(s) = \left(\prod_{k=0}^K \left(\frac{1}{\left[\frac{T}{2^k}\right]} \sum_{t=1}^{\left[\frac{T}{2^k}\right]} \left| \frac{(p_{t-1} - p_t)}{p_t} \right| \right) \right)^{\frac{1}{K+1}}$$

ここで、 $K \geq 0$, $2^{K+1} \leq T$ 。

予測ポイントからの全 T 期間の平均変動率も、予測起点から $\left[\frac{T}{2}\right]$ までの平均変動率も、 \dots , $\left[\frac{T}{2^k}\right]$ までの平均変動率もバランスよく高くなるように算術平均と幾何平均の組み合わせを基準に上位を選んでいく。例えば、 $T = 2000$, $K = 5$ の場合、予測ポイントからそれぞれ向こう 2000, 1000, 500, 250, 125, 62 日間の絶対変動率の算術平均を計算してから幾何平均を計算する。

$P_2 = 80\%$ とした場合、 $|\mathcal{S}_3|$ は 576 前後になる。

Step4 $\mathcal{S}_3 \cup \{s_0\}$ から s_0 の s に対する平均絶対ベータ値の高い上位 N 個の銘柄を選び、 s_0 のベース銘柄集 $\mathcal{S}(s_0)$ とする。前の各 Step で s_0 が落とされる可能性があるため、ここで s_0 がベース銘柄集に入るようにしておく。今回の実験で $|\mathcal{S}(s_0)| = N = 400$ とした。

s_0 とある銘柄 $s \in \mathcal{S}_3$ の学習期間+ L 日目の t 日目の終値時系列をそれぞれ $p_t^0, p_t^s, t = 1, 2, \dots, T, T+1, \dots, T+L$ とし、 s_0 の s に対する平均絶対ベータ値 $AvgBeta(s_0 | s)$ を次のように定義する。

$$a_t^0 = \frac{1}{L} \sum_{i=1}^L p_{t+i}^0, \quad a_t^s = \frac{1}{L} \sum_{i=1}^L p_{t+i}^s$$

ここで L は属性ウィンドウのサイズ、 a_t^0 と a_t^s 、 $t = 1, 2, \dots, T$ はそれぞれ L 日間の移動平均値である。

$$\alpha_k = \left\{ \frac{p_1^0 - a_1^0}{a_1^0}, \frac{p_2^0 - a_2^0}{a_2^0}, \dots, \frac{p_{\lfloor \frac{T}{2^k} \rfloor}^0 - a_{\lfloor \frac{T}{2^k} \rfloor}^0}{a_{\lfloor \frac{T}{2^k} \rfloor}^0} \right\}$$

$$\beta_k = \left\{ \frac{p_1^s - a_1^s}{a_1^s}, \frac{p_2^s - a_2^s}{a_2^s}, \dots, \frac{p_{\lfloor \frac{T}{2^k} \rfloor}^s - a_{\lfloor \frac{T}{2^k} \rfloor}^s}{a_{\lfloor \frac{T}{2^k} \rfloor}^s} \right\}$$

$$\text{AvgBeta}(s_0 | s) = \left(\prod_{k=0}^K \left| \frac{\alpha_k \cdot \beta_k}{\beta_k} \right| \right)^{\frac{1}{K+1}}$$

ここで、 $K \geq 0$ 、 $2^{K+1} \leq T$ 。

ここでもやはり予測ポイントからの各 $\lfloor \frac{T}{2^k} \rfloor$ 、 $k = 0, \dots, K$ までの平均絶対ベータ値がバランスよく高くなるように幾何平均を基準に上位を選んでいる。一般的には他の銘柄の日経平均に対するベータ値を計算するが、ここではその逆である。

以上の各ステップをまとめると、できるだけ売買不成立日が少く、時価総額が大きく、変動率が大きく、予測対象銘柄の変動への貢献度が高い銘柄をベース銘柄集に選ぶことになる。本研究では、各ステップの順番も重要である。

4.2 属性値の決定

機械学習の場合、何を入力データの構成要素にするのが重要ファクターの一つであり、学習率、及び識別率に大きな影響を及ぼす場合が多い。その構成要素として移動平均値とRSI (Relative Strength Index) の組み合わせを用いたり [6]、 n 日間の株価時系列データをそれぞれウィンドウ内と全学習期間内で正規化したデータの組み合わせを用いた [9] 研究がある。

本研究では、属性値としてある時点 t_0 から見た過去 L 日間の属性ウィンドウ (図1の(f)) とし、属性ウィンドウ内の株価終値の時点 t_0 の終値からのトリプルボトムとトリプルトップの変動率を入力データの属性値とする。 L は属性ウィンドウのサイズになる。

ある時点とその直前の属性ウィンドウ内の終値時系列を p_t 、 $t = 0, 1, 2, \dots, L = 3 \times 2 \times \text{skip}$ とした場合のトリプルボトムの変動率は次のように求める。

Step1 $\frac{p_t - p_0}{p_0}$ 、 $t = 1, 2, \dots, L$ を昇順にソートし、その結果を c_t 、 $t = 1, 2, \dots, L$ とする。

Step2 $t_1, t_2, t_3 \in \{1, 2, \dots, L\}$ 、 $t', t'' \in \{t_1, t_2, t_3\}$ 、 $|t' - t''| \geq \text{skip}$ になるように $\{c_{t_1}, c_{t_2}, c_{t_3}\}$ を選

ぶ。即ち、できるだけ下位3つを選ぶが、時系列的に隣ではなく、互いに skip 日以上離れた値を選ぶようにする。

Step3 $\{c_{t_1}, c_{t_2}, c_{t_3}\}$ を本の時系列順に戻し、トリプルボトムの変動率 $\{l_1, l_2, l_3\}$ を得る。

トリプルボトムと反対の方法でできるだけ上位3つを選ぶことで、トリプルトップの変動率 $\{h_1, h_2, h_3\}$ を求めることができる。

今回の実験は株価が上がるかどうかの予測に $\text{skip} = 3$ ($L = 18$)、株価が下がるかどうかの予測に $\text{skip} = 2$ ($L = 12$) として行う。

次に、予測対象銘柄 s_0 のベース銘柄集

$$\mathcal{S}(s_0) = \{s_1, s_2, \dots, s_N\}, N = |\mathcal{S}(s_0)|$$

において、 $s \in \mathcal{S}(s_0)$ の時点 t のトリプルボトムとトリプルトップの変動率を $\alpha_t^s = \{l_{t_1}^s, l_{t_2}^s, l_{t_3}^s, h_{t_1}^s, h_{t_2}^s, h_{t_3}^s\}$ とし、 $x_t^0 = \{\alpha_t^{s_1}, \alpha_t^{s_2}, \dots, \alpha_t^{s_N}\}$ 、 $t = 1, 2, \dots, T$ を一次的な入力データとする。一次的な入力データができた時点で、 x_t^0 を行に持つ行列 X^0 を作り、

$$X^0 = U \Sigma V^t$$

のように特異値分解し、行列 $X^0 V$ の各行を最終的な入力とする。また、予測を行う時の一次的な入力データ x_t^0 に関して、 $x_t = x_t^0 V$ を最終的な入力とする。

ここでは、一次的な入力データ x_t^0 で学習させるのがよいか、それとも特異値分解によって変換した後の x_t で学習させるのがよいかについて実験を行い、後者のほうが学習率でも識別率でも優れていることを確認済みであり、今回の実験でも後者を用いる。もちろん、特異値分解には時間がかかるが特異値分解後の学習時間が劇的に速く、一次的な入力データでの学習に時間がかかり、トータルで考えた場合、特異値分解+学習にかかる時間がそうではない場合の時間より数倍の範囲内で収まっている。

4.3 ラベル付け基準値の決定

入力データが決まったところで、次に問題になるのは教師データであるラベルを何を基準に決めるかということである。セクション2でも述べたように、次の日の一日の株価の値動きではなく、次の日から数日間のターゲットウィンドウ内の値動きを予測対象とする。ターゲットウィンドウのサイズを M とする。

従来の研究では、株価の値動きに関して0を基準にし、当日 t と前日 $t+1$ の株価の変動率 $RoC = \frac{p_t - p_{t+1}}{p_{t+1}}$ を計算し、 $RoC \geq 0$ の場合は「上がり」(+1)、そうではない場合は「下がり」(-1) にラベル付けして学習と予測を行うことが多い。しかし、本研究では「上が

り」と「下がり」の基準値を別々に決め、学習と予測も別々に行う。

「上がり」の基準値は次のように決める。

Step1 ターゲットウィンドウ内の終値のトップ $\frac{1}{3}$ の平均値の変動率 $TRoC(3)$ を計算する。
終値 $\{p_M, p_{M-1}, \dots, p_1\}$ からトップ $m(3)$ を選び、 $h_1, \dots, h_{m(3)}$ とし、

$$TRoC(3) = \left(\frac{1}{m(3)} \sum_{i=1}^{m(3)} h_i - p_{M+1} \right) / p_{M+1}$$

$$\text{ここで, } m(3) = \begin{cases} 1 & \text{if } \frac{M}{3} < 1 \\ \lceil \frac{M}{3} \rceil & \text{otherwise} \end{cases}$$

Step2 学習期間内の $t = 1, 2, \dots, T$ に対して、**Step1** の $TRoC(3)$ を計算して降順に並べた

$$r_1, r_2, \dots, r_{\lceil \frac{T}{3} \rceil}, \dots, r_T$$

の中の $UR = r_{\lceil \frac{T}{3} \rceil}$ を「上がり」の基準値とする。

「上がり」と反対の方法で、ターゲットウィンドウ内の終値のボトム $\frac{1}{3}$ の平均値の変動率 $BRoC(3)$ を学習期間の全ての t に対して計算し、それを昇順に並べたものから「下がり」の基準値 $LR = r_{\lfloor \frac{T}{3} \rfloor}$ を求めることができる。

便宜上、これから時点 t の $TRoC(3)$ を $TRoC(t)$ 、 $BRoC(3)$ を $BRoC(t)$ とし、関数のように使用する。 UR と LR もそれぞれ「上がり」と「下がり」の基準値として使用する。

次に、ラベル付けの基準値 UR と LR が決定されたところで、

$$y_t^U = \begin{cases} +1 & \text{if } TRoC(t) \geq UR \\ -1 & \text{otherwise} \end{cases}$$

$$y_t^D = \begin{cases} +1 & \text{if } BRoC(t) \leq LR \\ -1 & \text{otherwise} \end{cases}$$

$$t = 1, 2, \dots, T$$

によってそれぞれ「上がり」と「下がり」のラベル付けを行う。そして、

$$Y^U = \{y_1^U, y_2^U, \dots, y_T^U\}, \quad Y^D = \{y_1^D, y_2^D, \dots, y_T^D\}$$

$X = X^0V$ (セクション4.2) とし、 $\{X, Y^U\}$ と $\{X, Y^D\}$ でそれぞれ上がるかどうか、下がるかどうかの学習を行う。

4.4 日経平均株価指数の予測実験

本研究で実験を行うためにまず参考文献 [10] に基づいて、実用に近い「SCW 学習・予測システム」を実装した。セクション3で述べた通り、SCW モデルの構造が極めてシンプルであり、本体部分の実装だけ考えれば、一般的なプログラミング言語と既存の Library を利用すれば数十行で済む。むしろデータの入手と加工のためのプログラミングに手間がかかったぐらいである。

今回の実験に使用するデータとして、東京証券取引所に上場している銘柄のうち、2016年2月末の時点で時価総額50億円以上、2003年以前から上場している1000銘柄前後、及び日経平均株価指数の時系列データをYahoo!ファイナンス [12] から取得した。そして日経平均株価指数を予測対象にし、複数の実験を行った。

本研究の原則は、予測しやすい銘柄だけを予測し、「上がる」、あるいは「下がる」と予測できたタイミングでしか売買しない。従って、実験結果もこの原則に基づいて評価する。

実験の前提条件は以下の通りである。

学習期間: $T = 2000$

セクション4.1の K : $K = 5$

ベース銘柄数: $|S(\text{日経平均})| = 400$

ターゲットウィンドウサイズ: $M = 3$

予測テスト期間: 2015年9月1日～2016年2月29日

属性ウィンドウサイズ: 「上がる」の場合 $L = 18$,

「下がる」の場合 $L = 12$

また、上がるかどうかと下がるかどうかは別々に学習し、別々に予測した。つまり、「上がる」の場合、上がると予測したものの中で何割正解があったかだけを問い、そうでない場合は問わないし、「下がる」の場合、下がると予測したものの中で何割正解があったかだけを問い、そうでない場合は問わない。

4.4.1 SCW の識別能力に関する実験

一つの学習モデルの予測正解率が何%までなら識別能力があると判断されるかについて基準がないだろうが、理論的には51%以上なら識別能力があると考えられる。一方、学習モデルによって学習・予測の対象になるデータの種類や特徴が違えば、その識別能力が上下する場合も考えられる。そこでSCWのモデルを利用した場合、どこまで予測可能かについて2015年9月1日から2016年2月29日までの半年の日経平均株価指数を対象に「上がる」と「下がる」の両方の実験を行った。その結果を図2と図3に示す。

図2と図3では、x軸は「上がる」「下がる」と判断した日付、y軸は日付の次のターゲットウィンドウの株価変動率(%)を表す。そして「上がる」に関しては83%、




図 2: 「上がる」の場合




図 3: 「下がる」の場合




図 4: 「上がる」の場合




図 5: 「下がる」の場合

「下がる」に関しては 79%の正解率になった。この結果から、本研究の手法は有効であると判断できる。

4.4.2 売買タイミングに関する実験

本研究では、上がるかどうか、下がるかどうかを判断するだけでなく、上がるなら随分上がるか、下がるなら随分下がるかといった売買タイミングを見極めることにも重点をおいた予測を行う。その騰落の程度を定量的に測る指標としてセクション 2 の式 3 の通り、「騰落強度」を導入した。「騰落強度」が大きければ大きいほど、売買タイミングに近付いたと判断したい。

その目的のために、「上がる」「下がる」を判断した上に、騰落強度が大きければ、それに伴ってターゲットウィンドウの変動率も大きくなるかどうかについて調べた。売買タイミングに関しても「上がる」と「下がる」の両方の実験を行った。その結果を図 4 と図 5 に示す。

図 4 と図 5 では、x 軸は「上がる」「下がる」と判断した日付、y 軸は日付の次のターゲットウィンドウの株価変動率 (%) と騰落強度のスタックを表す。これらの結果から、「上がる」の場合も「下がる」の場合も騰落強度が大きければ大きいほど、変動率も大きくなる傾向にあることが分かる。「上がる」の場合は、平均値よ

り大きい騰落強度の場合、下がった銘柄が三つだけであり、「下がる」の場合も上がったのは三つであった。

また、図 4 と図 5 を併せて考えた場合、騰落強度が充分大きい時に株価が反対側になった場合はなく、そのようなタイミングが 10 回以上あり、半年でこれぐらいの回数のチャンスがあれば充分であると言える。このことから本研究の手法は有効であると判断できる。

5 結論

本研究では、オンライン学習の一つである Soft Confidence-Weighted Learning (SCW)[10] を利用し、株式の売買タイミングに重点をおいた株価の値動きを予測する手法を提案し、その有効性を示した。また、学習全体を「上がる」を主眼にした学習と「下がる」を主眼にした学習に分けて行った。株価の値動きに関して「上がる」「下がる」と予測されたものの中で実際にそうなった割合が 80%前後になった。

入力データを構成する属性値としてトリプルトップとトリプルボトムの変動率を組み合わせるという独自の方法を考案した。一つの銘柄の値動きを予測するためにその変動への貢献度の高い銘柄を動的に選択し、それらの属性値を組み合わせることも従来の研究ではあまり見られない。日経平均株価を構成する銘

柄が一年に一回入れ替えられており、似たようなところはあるが、今回提案した手法は機械的であり、主役銘柄が常に交代する現在のマーケットでは、今回提案した手法はより有効であると考える。

株式に関して、毎日その変動を予測して毎日売買しなければならないものではなく、「上がる」、「下がる」可能性が充分高くなった時点で売買を行い、一定以上の利益を確保する、あるいは損だけは出さないことは特に個人投資家にとって重要である。本研究では、その観点から、騰落強度を導入し、騰落強度が大きくなればなるほど変動率も大きくなる傾向にあることを確認した。

今後の課題として、ダウ平均株価指数、ナスダック平均株価指数等他の指数に関して同様の実験を検討していきたい。

謝辞

本研究を進めるにあたり、ご指導を頂いた恩師であり、名古屋大学名誉教授の稲垣康善先生に感謝致します。

参考文献

- [1] Hinton, G. , Osindero, S. and Teh, Y. W. : A fast learning algorithm for deep belief nets, *Neural Computation*, Vol. 18, No. 7, pp. 1527–1554 (2006)
- [2] Chao, J., Shen, F. and Zhao, J.: Forecasting exchange rate with deep belief networks, *Proceedings of IEEE International Joint Conference on Neural Networks (IJCNN)* , pp. 1259–1266(2011)
- [3] Yeh, S. , Wang, C. and Tsai, M.: Corporate Default Prediction via Deep Learning, In *The 34th International Symposium on Forecasting (ISF '14)*, (2014)
- [4] Aizerman, M., Braverman, E., and Rozonoer, L.: Theoretical foundations of the potential function method in pattern recognition learning, *Automation and Remote Control 25*, pp. 821–837 (1964)
- [5] Boser, B. E., Guyon, I. M., and Vapnik, V. N.: A training algorithm for optimal margin classifiers, *Proceedings of the fifth annual workshop on Computational learning theory (COLT '92)*, pp. 144–152 (1992)
- [6] 淵井 亮, 鍾 寧: サポートベクターマシンを利用した株価の値動き予測, 電子情報通信学会技術研究報告, *KBSE2010-42*, pp. 43–48 (2011)
- [7] Shen, S., Jiang, H., and Zhang, T.: Stock market forecasting using machine learning algorithms, *CS229 (Machine Learning) at Stanford University*, accessed February 1, 2016, <http://cs229.stanford.edu/proj2012/ShenJiangZhang-StockMarketForecastingusingMachineLearningAlgorithms.pdf> (2012)
- [8] Bengio, Y., Lamblin, P., Popovici, D., and Larochelle, H.: Greedy Layer-Wise Training of Deep Networks, *Advances in Neural Information Processing Systems 19 (NIPS 2006)*, accessed February 1, 2016, <http://papers.nips.cc/paper/3048-greedy-layer-wise-training-of-deep-networks.pdf> (2007)
- [9] 小牧昇平, 白山晋: Deep Belief Network を用いた日経平均株価の予測に関する研究, 人工知能学会研究会資料, SIG-FIN-012-08, (2014)
- [10] Wang, J., Zhao, P., and Hoi, S. C. H.: Exact Soft Confidence-Weighted Learning, *Proceedings of the 29th International Conference on Machine Learning (ICML 2012)* ,pp. 121–128 (2012)
- [11] 日経平均プロフィール, <http://indexes.nikkei.co.jp/nkave/>
- [12] Yahoo!ファイナンス, <http://finance.yahoo.co.jp/>
- [13] Dredze, M., Crammer, K., and Pereira, F.: Confidence-weighted linear classification, *Proceedings of the 25th International Conference on Machine Learning (ICML 2008)* , pp. 264–271 (2008)
- [14] Crammer, K., Kulesza, A., and Dredze, M.: Adaptive regularization of weight vectors, *Advances in Neural Information Processing Systems 22 (NIPS 2009)* , pp. 345–352 (2009)
- [15] Orabona, F. and Crammer, K.: New adaptive algorithms for online classification, *Advances in Neural Information Processing Systems 22 (NIPS 2010)* , pp. 1840–1848 (2010)
- [16] Ma, J., Kulesza, A., Dredze, M., Crammer, K., Saul, K.L., and Pereira, F.: Exploiting Feature Covariance in High-Dimensional Online Learning, *Proceedings of the 13th International Conference on Artificial Intelligence and Statistics (AISTATS 2010)*, accessed February 1, 2016, <http://jmlr.csail.mit.edu/proceedings/papers/v9/ma10a/ma10a.pdf> (2010)

ダーク・プールが市場効率性と価格発見メカニズムに与える影響 ～人工市場モデルと数式モデルを用いたメカニズムの分析～[†]

水田 孝信^{*1} 小杉 信太郎^{*2} 楠本 拓矢^{*3} 松本 渉^{*3} 和泉 潔^{*4}
Takanobu Mizuta Shintaro Kosugi Takuya Kusumoto Wataru Matsumoto Kiyoshi Izumi

^{*1}スパークス・アセット・マネジメント株式会社

^{*2}三菱UFJモルガン・スタンレー証券株式会社 ^{*3}野村證券株式会社

^{*4}東京大学大学院 工学系研究科

株式市場において、注文を公開せずに注文を付き合わせる、ダーク・プールという取引市場が普及してきている。ダーク・プールは市場の安定化につながると言われている一方、ダーク・プールは価格決定を行わない市場であるため、市場全体の価格発見機能が低下し、市場全体の効率性が失われるという批判もある。本研究では1つのリット市場(注文情報が公開されている通常の市場)と1つのダーク・プールが存在する人工市場モデル(マルチ・エージェント・シミュレーション)を用いて、ダーク・プールの普及が市場の効率性や発見機能にどのようなメカニズムで影響を与えるかを議論し、さらに、シンプルな数式モデルを提案し、可能性のあるメカニズムについて議論を深めた。その結果、ダーク・プール売買数量シェアある値より小さい領域で市場は効率化し、それを超えると非効率となることが分かった。これは最適なダーク・プール売買数量シェアが存在することを示している。

SOR(smart order routing)は成行注文をリット市場からダーク・プールへ回送するため、リット市場への約定率が低下する。これにより、リット市場での指値注文は厚くなり、これらが成行注文を吸収する。そのため、市場価格はファンダメンタル価格付近にとどまり市場は効率化する。しかし、ダーク・プールに多くの買い注文が待機しすぎると、市場価格をファンダメンタル価格へ収束させる成行注文がSORによりダーク・プールへ回送されて待機注文に吸収されてしまい、市場価格はファンダメンタル価格に収束しなくなる。そのため、市場は非効率になる。

また、シンプルな数式モデルを用いてダーク・プールが市場を効率化または非効率化するメカニズムを議論した。市場が効率化するか非効率化するかは、リット市場とダーク・プールの売買数量の大小関係が、本質的に重要であることを示した。ダーク・プールでの売買数量がリット市場での売買数量を超えると市場が非効率化する恐れがあることを示した。ダーク・プールの使用量が小さい場合、大きな売り買いの不均衡があっても、価格発見機能は破壊されないことを示した。一方、ダーク・プールの使用量が大きい場合、非常に小さな売り買いの不均衡によって、ダーク・プールは価格発見機能を破壊してしまうことが示した。そして、シミュレーション結果とも比較を行い、傾向は一致していることを確認した。

1. はじめに

株式市場において、注文を公開せずに注文を付き合わせる、ダーク・プールという取引市場が普及してきている[清水 13]。ダーク・プールは他の投資家に自分の注文を見せる必要がないため、大量の売買を行いたい投資家が、自らの大量の売買注文によって市場価格を変動させてしまうこと(マーケット・インパクト)を避けて売買ができる。このような大口投資家による大きなマーケット・インパクトを市場にもたらすことを少なくするため、市場の安定化につながると言われている[Johnson 10]。

しかしながら、価格決定機能を持たないダーク・プールが普及すると、市場全体の価格発見機能が低下し、市場が非効率になる恐れがあるという批判もある[Ye 12]。そのため、例えば欧州では、2014年の金融商品市場指令の見直し(MiFID II)によって、ダーク・プールでの売買代金を全体の8%に制限するキャップ規制が導入された[Bowley 14]。

ダーク・プールが今以上に普及した場合、市場を効率化すかどうか、実証研究で分析することは難しい。というのも、ダーク・プールが今以上に普及したことは過去に無いうえ、価格形成にはさまざまな要因が複雑に関わっており実証研究ではダーク・プールの効果だけを取り出すことが困難だからである。通常、このような新しいタイプの市場が普及すべきかどうかは、価格形成が効率的になるかどうかで議論される。

マルチ・エージェント・シミュレーションの一種である人

工市場を用いれば、これらの新しいタイプの市場の純粋な影響を抽出できるうえ、過去にないくらい使用された場合も議論することができる[LeBaron 06, Chen 12, 和泉 12, Cristelli 14, Mizuta 16]。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新しい規制や制度、新しいタイプの市場を分析してきた。

しかし、ダーク・プールを分析した人工市場シミュレーション研究は多くない。[Mo 13]は、ダーク・プールを人工市場で分析した研究であるが、実際の株価を参照しているなどしているため、これまで以上にダーク・プールが普及した場合など、過去にない環境がどのようになるかは分析していない。[Mizuta 15c]では、1つのリット市場(注文情報が公開されている通常の市場)と1つのダーク・プールが存在する人工市場モデルを構築し、アルゴリズム取引においてダーク・プールを使用することでマーケット・インパクトを減らせることを示した。[水田 15a]では、人工市場モデルを用いて、ダーク・プールの普及が市場を非効率にするのかどうかシミュレーションを行って分析した。そして、ダーク・プールの普及が、どのようなメカニズムで市場の効率性に影響を与えるのか議論を試みたが、メカニズムの解明には至っていない。

そこで本研究では、[水田 15a]を発展させて、ダーク・プールの普及が市場の効率性や発見機能にどのようなメカニズムで影響を与えるかを議論を行う。さらに、シンプルな数式モデルを提案し、可能性のあるメカニズムについて議論を深める。

2. 人工市場モデル

[Chiarella 02]では、シンプルでありながら、実証分析で得られた長期間に存在する価格変動の統計的性質を再現できるエージェントモデルの構築に成功している。取引市場の選択は、

連絡先: 水田 孝信, mizutata@gmail.com

[†] 本稿は [Mizuta 15b] を和訳し再構成したものである。発表時のスライドはこちらで閲覧できます。
<http://www.slideshare.net/mizutata/dark2016>

数ミリ秒、数マイクロ秒といった、高頻度に変化する注文状況を分析しながら注文を行うアルゴリズム・トレードなどで自動的に行われることが多い。そのため、取引市場の選択について分析を行うための人工市場モデルは、約定件数やキャンセル率、1ティックごとの騰落率の標準偏差など、高頻度な時間スケールでの性質（マーケット・マイクロ・ストラクチャー）を再現する必要がある。[Mizuta 15c]では、[Chiarella 02]のモデルでは再現されていなかった、これらのマーケット・マイクロ・ストラクチャーも再現した*1。[水田 15a]では、[Mizuta 15c]で実装されていなかった新たな市場選択モデルとして、SOR(smart order routing)を実装し、市場へ重要な影響を与えるリット市場からダーク・プールへの注文回送を再現した。

本研究では[水田 15a]の人工市場モデルを用いて分析を行う。本研究の目的にはモデルがシンプルであることはとても重要である。モデル構築の基本理念は付録にて説明した。

2.1 注文プロセス

本モデルは1つの証券のみを取引対象とする。 n 体のエージェントがあり、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、注文をただで取引が成立しない場合も1ステップ進む。各エージェント j は2.3節で述べる手順に従って、売りか買いか、注文価格 $P_{o,j}^t$ を決定する。注文数量は常に1と一定とする。また、各エージェントは資産を何単位でも買うことができ(キャッシュが無制限大)、空売りも自由に行うことができる。

2.2 リット市場とダーク・プール

本モデルでは、1つのリット市場(注文情報が公開されている通常の市場)と1つのダーク・プール(注文を公開せずに注文を付き合わせる市場)が存在する。

リット市場での価格決定メカニズムは、売り手と買い手の双方が価格を提示し、売り手と買い手の提示価格が合致するとその価格で直ちに取引が成立する、連続ダブルオークション方式(ザラバ方式)とした。価格の変化幅の最小単位は δP とし、それより小さい端数は、買い注文の場合は切り捨て、売り注文の場合は切り上げる。買い(売り)注文は、注文価格より安い(高い)注文が既に存在すれば、最も安い(高い)売り(買い)注文と即座に取引が成立する。このような即座に取引が成立する注文を成行注文*2とよぶ。即座に取引が成立する、相対する注文がなければ注文を残す。このように即座に成立せず残された注文を指値注文とよぶ。指値注文がキャンセル時間 t_c だけ経過しても取引が成立しなかった場合は、キャンセルされる。

ダーク・プールの取引価格の決定方法にはさまざまな方法があるが、本研究では実際の株式市場で広く用いられている、リット市場での最も高い買い注文価格と最も安い売り注文価格の平均である仲値を取引価格とする方式を用いた[Johnson 10]。ダーク・プールへの注文では価格を指定しない。1単位の買い(売り)注文を出した場合、もし相対する売り(買い)注文がすでにあれば、即座に売買が成立する。取引価格は、リット市場の最も高い買い注文価格と最も安い売り注文価格の平均とする。相対する売り(買い)注文がない場合は、注文を残し相対する注文を待つことになる。リット市場同様に残された注文がキャンセル時間 t_c だけ経過しても取引が成立しなかった

場合は、キャンセルされる。ダーク・プールでは、買いまたは売りのどちらか一方のみの注文しか残されないこととなる。

2.3 市場選択モデル

SOR(smart order routing)*3による市場選択が行われる場合(SORあり)と行われない場合(SORなし)を調べた。

SORありの場合、成行注文でかつダーク・プールに該当する注文がある場合は、エージェントは必ずダーク・プールへ注文を出す。その他の場合は、SORなしの場合と同様に、エージェントは確率 d でダーク・プールへ注文を出しその他の場合はリット市場へ注文を出す。一方、SORなしの場合、エージェントは確率 d でダーク・プールへ注文を出しその他の場合はリット市場へ注文を出す。

実際にはダーク・プールにどのような指値注文が待機しているかは投資家には分からないが、成行注文の場合には投資家はまずダーク・プールに注文し、注文が成立しなければすぐに注文をキャンセルしてリット市場へ注文を出すということが、実際の市場では通常行われていることである。そのため、上記のSORありのモデルは妥当である。

2.4 エージェント

エージェントは、実際の市場の価格形成の性質を再現するために導入するものであり、stylized factや高頻度取引にかかわる統計量を再現する範囲内でなるべくシンプルなモデルとした。

エージェントは注文価格 $P_{o,j}^t$ 、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) $r_{e,j}^t$ は、

$$r_{e,j}^t = \frac{1}{w_{1,j} + w_{2,j} + u_j} \left(w_{1,j} \log \frac{P_f}{P^t} + w_{2,j} r_{h,j}^t + u_j \epsilon_j^t \right). \quad (1)$$

ここで、 $w_{i,j}$ は時刻 t 、エージェント j の i 項目の重みであり、シミュレーション開始時に、それぞれ0から $w_{i,max}$ まで一様乱数で決める。 u_j はエージェント j の3項目の重みであり、シミュレーション開始時に0から u_{max} まで一様乱数で決める。 \log は自然対数である。 P_f は時間によらず一定のファンダメンタル価格、 P^t は時刻 t での取引価格*4、 ϵ_j^t は時刻 t 、エージェント j の乱数項であり、平均0、標準偏差 σ_ϵ の正規分布乱数である。 $r_{h,j}^t$ は時刻 t にエージェント j が計測した過去リターンであり、 $r_{h,j}^t = \log(P^t/P^{t-\tau_j})$ である*5。ここで τ_j はシミュレーション開始時に1から τ_{max} までの一様乱数でエージェントごとに決める。

式(1)の第1項目はファンダメンタル価格と比較して安ければプラスの予想リターンを高めればマイナスの予想リターンを示す、ファンダメンタル価値を参照して投資判断を行うファンダメンタル投資家の成分である。第2項目は過去のリターンがプラス(マイナス)ならプラス(マイナス)の予想リターンを示す、過去の価格推移を参照して投資判断を行うテクニカル投資家の成分であり、第3項目はノイズを表している。

予想リターン $r_{e,j}^t$ より予想価格 $P_{e,j}^t$ は、

$$P_{e,j}^t = P^t \exp(r_{e,j}^t) \quad (2)$$

*3 SORはさまざまな意味で用いられる(例えば[杉原 10]に詳しい)が、本研究の定義は必ずしも一般的なSORの定義でないことに注意すべきである。

*4 取引されなかった時刻では最も最近取引された価格であり、時刻 $t = 0$ では $P^t = P_f$ とする

*5 ただし、 $t < \tau_j$ のときは、 $r_{h,j}^t = 0$ とした。

*1 モデルのパラメータ決定の詳細は[水田 14]に書かれている。

*2 本研究が定義する成行注文、指値注文が実務上のそれらと厳密には異なることに注意すべきである。




図 1: 市場非効率性 M_{ie} (SOR あり, なし).




図 2: 約定率 k (SOR あり, なし).

で求まる. 注文価格 $P_{o,j}^t$ は平均 $P_{e,j}^t$, 標準偏差 P_σ の正規分布乱数で決める. ここで, P_σ は定数である. そして, 売り買いの別は予想価格 $P_{e,j}^t$ と注文価格 $P_{o,j}^t$ の大小関係で決める. すなわち,

$$\begin{aligned} P_{e,j}^t > P_{o,j}^t &\text{なら 1 単位の買い} \\ P_{e,j}^t < P_{o,j}^t &\text{なら 1 単位の売り,} \end{aligned} \quad (3)$$

とする*6.

3. シミュレーション結果

[Mizuta 15c]では, 長期間に存在する価格変動の統計的性質や高頻度な時間スケールでの性質を再現でき, ダーク・プールが市場に与える影響のメカニズムの分析に用いるのに妥当なモデルのパラメータを調べた*7. 具体的には, $n = 1,000, w_{1,max} = 1, w_{2,max} = 10, u_{max} = 1, \tau_{max} = 10,000, \sigma_\epsilon = 0.06, P_\sigma = 30, t_c = 20,000, \delta P = 0.1, P_f = 10,000$ とした. またシミュレーションは時刻 $t = t_e = 10,000,000$ まで行った.

3.1 市場効率性

本研究では, $d = 0, 0.025, 0.05, 0.075, 0.1, 0.125, 0.15, 0.175, 0.2, 0.25, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9$ と変化させ, その他の条件を乱数表も含め全く同じにして, 各種統計値を

*6 ただし, $t < t_c$ のときは, $P_f > P_{o,j}^t$ なら 1 単位の買い, $P_f < P_{o,j}^t$ なら 1 単位の売りとする.

*7 モデルの妥当性検証については付録で説明した.

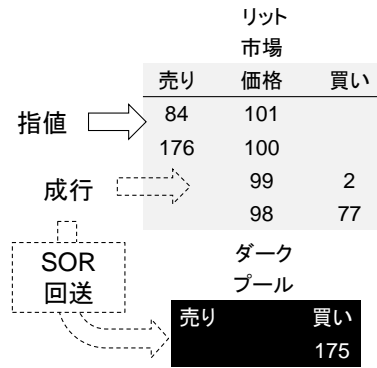


図 3: SOR の回送による約定率減少のメカニズム.




図 4: 指値注文の厚さとビッド・アスク・スプレッド.

$\delta l / \delta o$ に対して算出する. これを乱数表を変更して 100 回行い, その平均値を以後用いる.

市場の効率性を測定する指標として, 市場非効率性 M_{ie} ,

$$M_{ie} = \frac{1}{t_e} \sum_{t=1}^{t_e} \frac{|P^t - P_f|}{P_f}, \quad (4)$$

を定義した*8. ここで $||$ は絶対値を示す. M_{ie} は 0 以上の値をとり, 0 なら完全に効率的, 大きくなればなるほど非効率であることを示す.

図 1 はダーク・プール売買数量シェア (D) ごとの市場非効率性 (M_{ie}) を SOR(Smart Order Routing) ありの場合と SOR なしの場合で示した. ここで D はダーク・プールへの注文確率 d とは異なることに注意. V_D をダーク・プールにおける売買数量合計, V_L をリット市場でのそれとしたとき, D は $D = V_D / (V_D + V_L)$ と定義される. d は指値注文を含めた全ての注文数量のシェアであるのに対し, D は売買が成立する成行注文のみを数え上げて計算したシェアである.

図 1 が示すように, SOR なしの場合, M_{ie} は単調に, 徐々に減少している. 一方, SOR ありの場合, $D \lesssim 70\%$ では大きく減少し, $D \gtrsim 70\%$ では急上昇している. これは最適な D

*8 市場の効率性を示す指標は多く提案されている ([伊藤 07, Verheyden 13]) が, 本研究で用いる市場非効率性は, 通常は観測できないファンダメンタル価格 P_f を直接使用しており, 人工市場シミュレーションでしか用いることができない定義である. 人工市場シミュレーションでは P_f が明確であるため, 推定ではない理想的な市場の効率性を測定できる市場非効率性の使用が可能である.




図 5: 市場効率化のメカニズム。




図 6: 市場価格 (P^t) ごとのダーク・プールでの待機注文数と平均予想リターン ($r_{e,j}^t$)

が存在することを示している。以降、3.2 節では $D \lesssim 70\%$ で M_{ie} が減少する理由を、3.3 節では $D \gtrsim 70\%$ で M_{ie} が急上昇する理由を議論する。

3.2 最適な D 未満での市場の効率化

図 2 は D ごとのリット市場の約定率 (成行注文数/(成行注文数+指値注文数)) を SOR ありとなしの場合で示した。SOR なしの場合、約定率は少しずつ減少している。一方、SOR ありの場合、もっと速く減少している。これは SOR が約定率を削減させる効果を持つことを示している。

図 3 は SOR の回送による約定率減少のメカニズムを示している。2.3 節で述べたように、ダーク・プールに対当する待機注文がある場合、SOR によって成行注文はダーク・プールへ回送される。その他の場合は、ダーク・プールへの注文確率は d である。そのため、リット市場への注文数量は、対当する待




図 7: リット市場が非効率化されるメカニズム。

機注文がダーク・プールにある場合にダーク・プールへ回送される成行注文の分だけ、減少することになる。それゆえ、約定率は SOR が無い場合に比べ低くなる。

このメカニズムは、リット市場への成行注文に対する指値注文の割合を増加させる。図 4 は、SOR ありの場合の D ごとの指値注文の厚さとビッド・アスク・スプレッドを示している。ここで、指値注文の厚さは、 $(1 - 0.001) \times P^t$ (市場価格) から P^t までに存在する指値買い注文数量の平均を 1 日 (20,000 期間) の平均売買数量で割ったもの、ビッド・アスク・スプレッドは、もっとも高い買い指値注文ともっとも安い売り指値注文の価格の差をファンダメンタル価格 P_f で割ったものと定義した。 D が増えると、指値注文の厚さは増し、それによってビッド・アスク・スプレッドとは縮小している。

図 5 は指値注文が厚くなることによってリット市場が効率になるメカニズムを示した。まず、 P^t が P_f 付近だったとする。指値注文が厚い場合、 P_f から離れる成行注文が出たとしても、厚い指値注文がそれらの成行注文を吸収し、 P^t は P_f 付近にとどまる。

図 3 と図 5 を用いて $D \lesssim 70\%$ で M_{ie} が減少する理由をまとめる。 D の増加により成行注文がダーク・プールへ回送されるため、リット市場への約定率が低下する。これにより、リット市場での指値注文は厚くなり、これらが成行注文を吸収する。そのため、市場価格はファンダメンタル価格付近にとどまることとなるのである。

3.3 高すぎる D による市場非効率化

$D \gtrsim 70\%$ で M_{ie} が急上昇する理由を議論する。図 6 は、市場価格 (P^t) ごとのダーク・プールでの待機注文数と平均予想リターン ($r_{e,j}^t$) を、 $D = 44\%$ と 96% で SOR ありの場合を示した。待機注文数がプラスのときは買い注文、マイナスのときは売り注文であることを示す。 $D = 44\%$ のとき、ダーク・プールでの待機注文は少なく、 P^t が $P_f (= 10,000)$ より大きいときは $r_{e,j}^t$ はプラスであり、 P^t が P_f より小さいときは $r_{e,j}^t$ はマイナスである。一方、 $D = 96\%$ のとき、ダーク・プールには多くの注文が待機しており、 $r_{e,j}^t$ の符号は $D = 44\%$ のときと逆である。

図 7 は、リット市場が非効率化されるメカニズムを示した。いったん P^t が P_f より大きくなって離れたとき、ダーク・プールには多くの買い注文が待機しており、 $r_{e,j}^t$ はマイナスであるため、成行売り注文が多く出される。これらの成行売り注文は P^t を下落させて P_f に近づける方向ではある。しかし、ダーク・プールには多くの買い注文が待機しており、これらの成行売り注文を吸収してしまい、 P^t が P_f に近づくのを妨げる。よって、 P^t は P_f から離れた状態が維持されてしまい、リット市場は非効率となる。これらは、いったん P^t が P_f より小さくなって離れたときも同様である。これが、 $D \gtrsim 70\%$ で M_{ie} が急上昇する理由である。

4. 理論的な議論

4.1 シンプルな数式モデル

この節では、シンプルな数式モデルを用いてダーク・プールが市場を効率化または非効率化するメカニズムを議論する。

ここで、買い注文をだす確率を a 、SOR なしの場合でリット市場で成行注文を出す確率を k 、ダーク・プールに注文を出す確率を d とする。 d は前節までの定義と同じである。明らかに、 $1 - a$ は売り注文を出す確率、 $1 - k$ はリット市場で指値注文を出す確率、 $1 - d$ はリット市場に注文を出す確率である。

表 1: 注文種類ごとの発生確率.

		リット市場 (1-d)	ダーク・プール (d)
買い (a)	成行 (k)	ak(1-d)	ad/2
	指値 (1-k)	a(1-k)(1-d)	ad/2
売り (1-a)	成行 (k)	(1-a)k(1-d)	(1-a)d/2
	指値 (1-k)	(1-a)(1-k)(1-d)	(1-a)d/2

シミュレーション結果では、ダーク・プールでの待機注文がキャンセルことはほとんどなかった。つまり、これらの注文はほとんどすべて成行注文と対当して取引が成立しており、ダーク・プールにおける指値注文と成行注文はほぼ同数であることを意味している。よって、ここではダーク・プールでの指値注文と成行注文を出す確率はいずれも 1/2 とした。

これらの定義から、例えばリット市場に成行買い注文が出る確率は $ak(1-d)$ であるといった計算ができる。このような場合すべてを表 I にまとめた。

なお、表 I より D (ダーク・プール売買数量シェア) を導くことができ^{*9},

$$D = \frac{d/2}{k(1-d) + d/2}. \quad (5)$$

表 I からシンプルな数式モデルを構築しシミュレーション結果と比較しながら、まずは最適な D 未満での市場効率化について分析する。

4.2 最適な D 未満での市場効率化

まず SOR ありのときの約定率 (k') を考えよう。簡単のため $a = 1/2$ とし、買いと売りの場合を合計する。すると、表 I より表 II が得られる。

SOR はリット市場への成行注文を出す確率 $k(1-d)$ を減少させる。 $k(1-d) > d/2$ のとき、つまり、リット市場の売買数量の方がダーク・プールのそれより大きい場合 ($D < 1/2$ と厳密に同じである)、リット市場に出された成行注文で SOR によってダーク・プールへ回送される注文の数は、ダーク・プールへ出される指値注文の数で上限が決まる。つまり、SOR によってリット市場への成行注文がどれだけ減るかは、ダーク・プールへの指値注文数で決まる。ゆえに、SOR によってリット市場への成行注文が出る確率の減少量を $ad/2$ と定義する。ここで α は 0 から 1 までの定数である。よって、リット市場に成行注文が出る確率は $k(1-d) - \alpha d/2$ となる。

一方、 $k(1-d) > d/2$ のとき、リット市場に出された成行注文で SOR によってダーク・プールへ回送される注文の数は、リット市場に出された成行注文の数自体で決まる。というのも、ダーク・プールにはそれを上回る十分な待機注文が存在するからである。ゆえに、SOR によってリット市場への成行注文が出る確率の減少量を $\alpha k(1-d)$ と定義し、リット市場に成行注文が出る確率は $k(1-d) - \alpha k(1-d)$ となる。

以上より、 $k(1-d) > d/2$ ($D < 1/2$) のとき、式 (5) より、

k' は、

$$k' = \{k(1-d) - \alpha d/2\} / (1-d) \quad (6)$$

$$= \left(1 - \alpha \frac{D}{1-D}\right) k, \quad (7)$$

$k(1-d) < d/2$ ($D > 1/2$) のとき、式 (5) より、 k' は、

$$k' = \{k(1-d) - \alpha k(1-d)\} / (1-d) \quad (8)$$

$$= k(1-\alpha). \quad (9)$$

これら 2 つの式は $k(1-d) = d/2$ で同じになると考えられるので、簡単に $\alpha = 1/3$ が得られる^{*10}。最終的に、

$$k' = \left(1 - \frac{1}{3} \frac{D}{1-D}\right) k \quad (D < \frac{1}{2} \text{ のとき}) \quad (10)$$

$$k' = \frac{2}{3} k \quad (D > \frac{1}{2} \text{ のとき}). \quad (11)$$

が得られる。

図 8 は、式 (10)、式 (11) から求めた約定率 (k') とシミュレーション結果 (図 2) から求めた約定率 (SOR ありのときの値から SOR なしのときの値を引いたもの) である。 $D = 0$ での約定率がシミュレーション結果と一致するようにゼロ点調整している。シミュレーションは SOR ありのときの値から SOR なしのときの値を引いたものを使用したのは、式 (10)、式 (11) は、SOR による約定率減少しか含んでいないため、シミュレーション結果からも SOR の効果のみを取り出したいためである。

式 (10)、式 (11) の k' は、 $D < 1/2$ のときと $D > 1/2$ のときで傾向が大きく異なる。 $D < 1/2$ のとき、SOR によってダーク・プールへ回送される注文数は、ダーク・プールへ出される注文数で決まる。これは、ダーク・プールへの注文数が増えれば (D が増えれば)、SOR で回送される注文数も増えることを意味する。そのため、 D が増えれば、 k' が減少する。一方、 $D > 1/2$ の場合、SOR によってダーク・プールへ回送される注文数はリット市場への成行注文数で決まる。これは、 D が増えても、SOR で回送される注文数が増えないことを意味する。ゆえに、 D が増えても k' は減らない。

市場が効率化するか非効率化するかは、リット市場での成行注文数とダーク・プールでの指値注文数の大小関係、つまり、 $D > 1/2$ であるか $D < 1/2$ であるかが、本質的に重要であることを示している。そして、最適なダーク・プールの使用量は $D = 1/2$ であることを示唆している。

*9 本研究のモデルではすべてのエージェントは 1 単位ずつ注文を出す。そのため、 D はダーク・プールに成行注文が出される確率をリット市場またはダーク・プールに成行注文が出される確率で割ったものと、厳密に一致する。

*10 $\alpha = 1/3$ となる理由を以下のように考えることもできる。ダーク・プールには買いの待機注文がある場合、売りがある場合、待機注文がない場合の 3 つの状態がある。その 3 つの状態が等確率で起こると仮定するならば、対当する注文が存在するのみ SOR による回送が起こるが、それら 3 つの状態のうち 1 つのみがそれである。よって、 $\alpha = 1/3$ となる

表 2: 注文種類ごとの発生確率 ($a = 1/2$ とし売り買い合算).

	リット市場 ($1-d$)	ダーク・プール (d)
成行 (k)	$k(1-d)$	$d/2$
指値 ($1-k$)	$(1-k)(1-d)$	$d/2$

シミュレーション結果 (SOR あり-SOR なし) を数式モデルの結果と比べると, $D < 1/2$ のとき k' が減少し, $D > 1/2$ のとき k' が安定しているという傾向は一致している. しかし, 減少の形は異なる. 数式モデルでは上に凸であるが, シミュレーションでは下に凸であり, 安定する水準も少し異なる. これらの違いは SOR 以外の効果から来ると考えられるが, 今後の課題である.

4.3 高すぎる D による市場非効率化

ここでは, 高すぎるダーク・プールの使用率が市場を非効率にする理由を述べる.

D が $1/2$ より十分大きく, ダーク・プールには十分多くの買い注文が待機しており, かつ, 市場価格はファンダメンタル価格より十分高い状況を考えよう. このとき, すべてのリット市場への成行売り注文が SOR によってダーク・プールへ回送される. よって表 I より, ダーク・プールへ売り注文が出る確率は, $(1-a)d + k(1-a)(1-d)$ となる. 当然, ダーク・プールへの買い注文が出る確率は ad である. もしダーク・プールにおいて, 新たに出される買い注文数量が売り注文数量より多くなれば, すなわち,

$$ad > (1-a)d + k(1-a)(1-d), \quad (12)$$

となれば, ダーク・プールで待機している買い注文数量は減少せず, 市場価格がファンダメンタル価格に収束するのを妨げる. そのため, 式 (12) はリット市場の価格発見機能を破壊する条件であるといえる.

式 (5) を用いると, 式 (12) は

$$a > \frac{1+D}{1+3D}. \quad (13)$$

と書き換えることができる. a は買い注文を出す確率であった. 言い換えれば a は, 全注文のうち買い注文が占める割合であり, $1-a$ は売りのそれである. それゆえ a は, 買いと売りの注文数量の不均衡を示しており, $a = 50\%$ のときは買いと売りの注文数量が完全にバランスしている状態を, $a = 100\%$ のときはすべての注文が買いになり売り注文が存在しない状態である. そして, $a = (1+D)/(1+3D)$ は, 価格発見機能が破壊されるかどうかの境界を示している. なお, 売り注文が多い場合もまったく同じ議論である.

図 9 は, D ごとの $a = (1+D)/(1+3D)$ を示している. この線の上が式 (13) を満たす領域である. $D = 20\%$ のとき, $a = 75\%$ である. もし, 買い注文が 75% 以上を占めれば, つまり売り注文が 25% 以下しかなく, 買い注文が売り注文の 3 倍以上あるという不均衡が起きれば, 価格発見機能が破壊される. このような状況は非常に大きな売り買いの不均衡と言えるので, まれにしか起きないと考えられる. よって $D = 20\%$ のときは, 価格発見機能が破壊されることはあまりないと考えられる.




図 8: 式 (10), 式 (11) から求めた約定率 (k') とシミュレーション結果 (図 2) から求めた約定率 (SOR あり-SOR なし).




図 9: 価格発見機能を破壊する売り買い不均衡 ($a = (1+D)/(1+3D)$) の水準.

一方, $D = 90\%$ のときは, $a = 51\%$ と非常に小さな売り買いの不均衡によって, ダーク・プールは価格発見機能を破壊してしまうことが示される.

5. 結論と今後の課題

本研究では, [水田 15a] を発展させて, 注文を公開せずに注文を付き合わせるダーク・プールの普及が市場の効率性や発見機能にどのようなメカニズムで影響を与えるか議論行い. さらに, シンプルな数式モデルを提案し, 可能性のあるメカニズムについて議論を深めた.

その結果, ダーク・プール売買数量シェア (D) が $D \lesssim 70\%$ では, 市場非効率性 (M_{ie}) が大きく減少し, $D \gtrsim 70\%$ では急上昇していることが分かった. これは最適な D が存在することを示している.

図 3 と図 5 を用いて $D \lesssim 70\%$ で M_{ie} が減少する理由を示した. D の増加により成行注文がダーク・プールへ回送されるため, リット市場への約定率が低下する. これにより, リット市場での指値注文は厚くなり, これらが成行注文を吸収する. そのため, 市場価格 (P^t) はファンダメンタル価格 (P_f) 付近にとどまることとなるのである.

図 7 を用いて, リット市場が非効率化されるメカニズムを示した. いったん P^t が P_f より大きくなって離れたとき, ダーク・プールには多くの買い注文が待機しており, 予想リターン ($r_{e,j}^t$) はマイナスであるため, 成行売り注文が多く出される. これらの成行売り注文は P^t を下落させて P_f に近づける方向

ではある。しかし、ダーク・プールには多くの買い注文が待機しており、これらの成行売り注文を吸収してしまい、 P^t が P_f に近づくのを妨げる。よって、 P^t は P_f から離れた状態が維持されてしまい、リット市場は非効率となる。これらは、いったん P^t が P_f より小さくなって離れたときも同様である。これが、 $D \geq 70\%$ で M_{ie} が急上昇する理由である。

また、シンプルな数式モデルを用いてダーク・プールが市場を効率化または非効率化するメカニズムを議論した。市場が効率化するか非効率化するかは、リット市場での成行注文数とダーク・プールでの指値注文数の大小関係、つまり、 $D > 1/2$ であるか $D < 1/2$ であるかが、本質的に重要であることを示している。そして、最適なダーク・プールの使用量は $D = 1/2$ であることを示唆している。つまり、ダーク・プールでの売買数量がリット市場での売買数量を超えると市場が非効率化する恐れがあることを示した。そして、シミュレーション結果とも比較を行い、傾向は一致していることを確認した。

さらに、格発見機能が破壊される売り買いの不均衡の境界を導いた。 D が小さい場合、例えば $D = 20\%$ のとき、 $a = 75\%$ である。もし、買い注文が 75% 以上を占めれば、つまり売り注文が 25% 以下しかなく、買い注文が売り注文の 3 倍以上あるという不均衡が起きれば、価格発見機能が破壊される。このような状況は非常に大きな売り買いの不均衡と言えるので、まれにしか起きないと考えられる。よって $D = 20\%$ のときは、価格発見機能が破壊されることはあまりないと考えられる。一方、 D が大きい場合、例えば $D = 90\%$ のときは、 $a = 51\%$ と非常に小さな売り買いの不均衡によって、ダーク・プールは価格発見機能を破壊してしまうことが示される。

今後の課題は、ダーク・プールの普及のしすぎの水準をさらに精緻にすることである。欧州では、2014 年の金融商品市場指令の見直し (MiFID II) によって、ダーク・プールでの売買代金を全体の 8% に制限するキャップ規制が導入された ([Bowley 14]) が、規定した 8% という水準が適切であるかどうかを議論するためには、さらに精緻な分析が必要である。

もうひとつの今後の課題は、本研究のシミュレーション結果と実証分析の比較である。確かに、実際の市場ではファンダメンタル価格が分からないため、 M_{ie} は計測できない。一方で、各銘柄のリット市場での約定率、指値注文の厚さ、ビッド・アスク・スプレッドの実際の市場での値は計測できる。さらに、各種統計量から各銘柄の D を推計することができる。 D は銘柄ごとに異なる。そのため、異なる D および約定率などをもつ各銘柄をプロットすることにより図 2・図 4 のような図を実際の市場のデータから作成可能である。それらと、本研究の図 2・図 4 と比較することにより、シミュレーション結果と実証分析の比較が可能である。

売り買いの不均衡も実際のリット市場のデータから観測可能である。これと、本研究の図 10 を使えば、実際の市場ではどのくらいの D で、価格発見機能が破壊されるかを議論することができる。

既に述べたように、人工市場シミュレーションはその導入の純粋な効果を見ることができるよう、過去に導入されたことがないものも分析することができる。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

マルチ・エージェント・シミュレーションの一種である人工市場を用いれば、これらの新しいタイプの市場の純粋な影響を抽出できるよう、過去にないくらい使用された場合も議論することができる。これが人工市場シミュレーション研究の強みである [Mizuta 16]。

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、これらの新しいタイプの市場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騰落率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。

以上より、本研究では、分析目的を果たせる範囲内であ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。

モデルの妥当性検証

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, 和泉 12, Cristelli 14, Mizuta 16]。ファット・テールは、市場価格の騰落率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・クラスターリングは市場価格の騰落率の 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 06] 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

表 3: リット市場のみの場合の各種統計量。

取引	約定率	32.3%		
	キャンセル率	26.1%		
	注文件数 / 1 日	6467		
標準 偏差	1 ティック	0.0512%		
	1 日 (20000 期間)	0.562%		
		尖度	1.42	
		ラグ		
		1	0.225	
二乗リターンの 自己相関係数			2	0.138
			3	0.106
			4	0.087
			5	0.075

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騰落率の分布の尖度は 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騰落率の自己相関は 0.01 ~ 0.2 程度と、かなりばらつきがある [Sewell 06]。

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 3 は、リット市場のみのときの統計量を示した。統計量は 100 回の試行の平均値を用いている。概ね $t = 20,000$ 期間で実際の市場での 1 営業日の約定 (売買成立) 件数に達するため、この期間を 1 営業日と定義した。約定率、キャンセル率ともにいずれのティックサイズにおいても実際の市場の値に近い値を得ており、モデルの妥当性を示唆している^{*11}。1 日 (20,000 期間) ごとの騰落率の標準偏差^{*12}も、概ね実際の市場に近い値が得られ、この側面からもモデルの妥当性を示唆している。

表 3 は、10 期間ごと^{*13}の騰落率を用いて計算した尖度と騰落率の 2 乗の自己相関も示している。騰落率の尖度がプラスで、実証分析でよく観測される 1 ~ 100 程度の範囲に収まっている。ゆえに、ファット・テールが再現されている。また、騰落率の 2 乗の自己相関もラグがあってもプラスで実証分析でよく観測される 0.01 ~ 0.2 程度に収まっている。ゆえに、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。

以上により、本研究のモデルが、約定件数やキャンセル率、1 日の騰落率の標準偏差など短期のマイクロ・ストラクチャーの性質および、長期に観測される価格変動の統計的な性質も再現していることが示された。それゆえ、本研究の目的である、ダーク・プールが与える影響の分析を行うのに妥当なモデルであることが示された。

*11 約定率 = 約定件数/注文件数, キャンセル率 = キャンセル件数/(注文件数+キャンセル件数)。

*12 本研究のシミュレーションではオーバーナイトが存在しないので、ここでの 1 日ごとの騰落率の標準偏差は、実際の市場のイントラデイのボラティリティに相当する。

*13 本モデルの時刻は注文をただ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ライズド・ファクトは多くの価格変動が無いデータによりバイアスがかかってしまうため、10 ステップ間隔での測定とした。

留意事項と謝辞

本論文はスパークス・アセット・マネジメント株式会社、三菱 UFJ モルガン・スタンレー証券株式会社および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。すべては個人的見解であります。野村證券株式会社エグゼクティブ・サービス部より実務上の観点から多くの有益な助言をいただきました。ここに感謝の意を表します。本研究の一部は、JST、CREST および JSPS 科研費 15H02745 の助成を受けたものです。

参考文献

- [Bowley 14] Bowley, A.: Agreement of MiFID II Reforms, Instinet incorporated (2014)
- [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 02] Chiarella, C. and Iori, G.: A simulation analysis of the microstructure of double auction markets, *Quantitative Finance*, Vol. 2, No. 5, pp. 346–353 (2002)
- [Cristelli 14] Cristelli, M.: *Complexity in Financial Markets, Modeling Psychological Behavior in Agent-Based Models and Order Book Models*, Springer (2014)
- [伊藤 07] 伊藤 幹夫, 杉山 俊輔: 市場効率性の変遷構造, in *KEIO ECONOMIC SOCIETY DISCUSSION PAPER*, No. 5, 慶応義塾大学 (2007)
- [和泉 12] 和泉 潔: 第 3 章 金融市場 – 人工市場の観点から, 杉原 正顕 (編), 計算と社会 (岩波講座 計算科学 第 6 巻), 岩波書店 (2012)
- [Johnson 10] Johnson, B.: *Algorithmic Trading & DMA: An introduction to direct access trading strategies*, 4Myeloma Press (2010)
- [LeBaron 06] LeBaron, B.: Agent-based computational finance, *Handbook of computational economics*, Vol. 2, pp. 1187–1233 (2006)
- [水田 14] 水田 孝信: 人工市場シミュレーションを用いた金融市場の規制・制度の分析, 博士論文, 東京大学大学院工学系研究科 (2014), http://www.geocities.jp/mizuta_ta/jphd.htm
- [水田 15a] 水田 孝信, 小杉 信太郎, 楠本 拓矢, 松本 渉, 和泉 潔: 人工市場シミュレーションを用いたダーク・プールによる市場効率化の分析, 第 14 回金融情報学研究会, Vol. 14, (2015), <http://sigfin.org/SIG-FIN-014-02/>
- [Mizuta 15b] Mizuta, T., Kosugi, S., Kusumoto, T., Matsumoto, W., and Izumi, K.: Effects of Dark Pools on Financial Markets' Efficiency and Price-Discovery Function: An Investigation by Multi-Agent Simulations, *Evolutionary and Institutional Economics Review*, Vol. 12, Issue 2, pp. 375–394 (2015), <http://dx.doi.org/10.1007/s40844-015-0020-3>
- [Mizuta 15c] 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*, (2015), <http://dx.doi.org/10.1002/isaf.1374>
- [Mizuta 16] Mizuta, T.: A Review of Recent Artificial Market Simulation Studies for Financial Market Regulations And/Or Rules, *SSRN Working Paper Series* (2016), <http://dx.doi.org/10.2139/ssrn.2710495>
- [Mo 13] Mo, S. Y. K. and Yang, M. P. S. Y.: A Study of Dark Pool Trading using an Agent-based Model, in *Computational Intelligence for Financial Engineering Economics (CIFER)*, 2013 *IEEE Symposium Series on Computational Intelligence on*, pp. 19–26 (2013)
- [Sewell 06] Sewell, M.: Characterization of Financial Time Series (2006), <http://finance.martinsewell.com/stylized-facts/>
- [清水 13] 清水 葉子: HFT, PTS, ダークプールの諸外国における動向～欧米での証券市場間の競争や技術革新に関する考察～, 金融庁金融研究センター ディスカッションペーパー (2013)
- [杉原 10] 杉原 慶彦: 取引コストの削減を巡る市場参加者の取組み: アルゴリズム取引と代替市場の活用, 日本銀行金融研究所 ディスカッション・ペーパー・シリーズ, No. J-26 (2010)
- [Verheyden 13] Verheyden, T., De Moor, L., and Bossche, Van den F.: A Tale of Market Efficiency, *Review of Business and Economic Literature*, Vol. 58, No. 2, pp. 140–158 (2013)
- [Ye 12] Ye, M.: Price manipulation, price discovery and transaction costs in the crossing network, *Price Discovery and Transaction Costs in the Crossing Network (March 14, 2012)* (2012)

人工市場を用いた集団行動バイアスが市場へ与える影響の 分析

Market Impact Analysis on Group Behavior by Artificial Market

王雅婷¹ 鳥海不二夫¹

Wang Yating¹, Toriumi Fujio¹

¹東京大学大学院 工学部研究科

¹School of Engineering, The University of Tokyo

Abstract: Humans have a strong tendency to belong to a group, which is called group behavior. It is said that group behavior may affect the financial market and make it inefficient. In this article, we study the relationship between group behavior and market impact by building an multi-agent based artificial market model. The results show that the market become more inefficient with group behavior growing when exceed some threshold.

1. はじめに

近年に急激な変動を経験した金融市場では、市場参加者であるディーラーの心理的な効果が注目されている[1]。特に集団行動バイアス（社会心理学の集団極化や集団的浅慮）が投資家の非合理行動をさせて、非効率市場の形成に重要な要素であると考えられている。

金融市場では、同じグループに属するディーラーがチャットや専用電話回線等で相互に密接に情報共有が図られているため、一種の集団を構成していると考えられる。集団におけるディーラーが他人の行動を重視し、他者への追従行動をとるインセンティブがあり、集団行動バイアスが起きる可能性が高まる。特に市場が激しい変動する時、投資家が自分の知識より正しい行動がとれるとは限らなく、周りの言葉や雰囲気によって流されて、非合理的な行動を取る傾向がある。

1.1 既存研究

従来から行動ファイナンスの研究において、投資家が集団行動バイアスによる行動特性と金融市場の間の関連を目的として研究が多数報告されている[2-3]。しかし、その多くが市場参加者の心理分析等の実証分析である。ミクロな各市場参加者の思考過程と行動や市場の内部構造の変化という詳細なレベルを測定することが難しい。Jurkatis[4]らは数値シミュレーションの手法で Avery ら[3]が提出した外部情報導入による集団行動モデルを実現し、集団行動密

度と市場へ影響の関係を証明したが、単にファンダメンタル分析に基づく投資家が市場に導入され、実際の金融市場に適用できない。このような現実世界のある複雑な現象を分析したい時、エージェントベースモデルが有効である。

人工市場はエージェントベースモデルの一種であり、現実の金融市場をもとにして、市場構造と市場参加者間の相互作用に着目して、コンピューター上に作ったモデルである。人工市場モデルを用いたシミュレーション研究が多数であり、実際の市場に見られる多くの金融現象を再現し、バブルや市場混乱期に金融市場における現象のマクロ・ミクロ相互作用のメカニズムを解明するなど多くの成果を上げている[5-6]。しかし、人工市場に関する既存研究の中、集団行動バイアスを導入した研究は存在しない。

1.2 本研究のモデル

本研究では、集団行動バイアスを持ち投資家の投資行動をモデル化して人工市場モデルを提案した。構築された人工市場モデルはエージェントと取引市場から構成されている。エージェントは一般的なエージェントと集団行動バイアスを持つ特別なエージェントを含んでいる。一般的なエージェントは水田らの人工市場モデル[7]をベースに、ファンダメンタル分析とテクニカル分析に基づく行動する投資家を模している。集団行動バイアスエージェントは自分の分析により行動だけではなく、前の取引行動を観測した結果と総合して行動する。もし他人の行動と自分の判断と異なる時、閾値により他人にフォロー

する可能性がある。

構築したモデルを用いて、集団行動バイアスによって投資家の行動は非合理的となり、その結果市場は非効率的となることを証明し、非効率市場における集団行動バイアスの閾値を解明する。さらに、集団行動バイアスを導入した各投資家の行動の積み重ねが市場混乱期の価格変動特性明らかにする。

2. 人工市場モデル

本人工市場モデルは一般的な投資家と集団行動バイアスを持つ投資家を含んでいる。一般的なエージェントはベースモデルのみを利用し、一部のエージェントが集団行動バイアスモデルに表現される。

本モデルは1つの株のみを取引対象として、市場取引はザラ場方式を用いる。

1.1 ベースモデル

ベースモデルの部分が、水田らの人工市場モデル[7]をベースに構築した。

N体のエージェントがおり、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 は取引が成立するかしないか関わらず1ステップを進む。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) $r_{e,j}^t$ は、

$$r_{e,j}^t = \sum_i \frac{1}{w_{i,j}} (w_{1,j} \log \frac{p_f}{p^t} + w_{2,j} r_{h,j}^t + w_{3,j} \epsilon_j^t) \quad (1)$$

となる。式(1)の第1項目はファンダメンタル価値を参照して投資判断を行うファンダメンタル投資家の成分である。第2項目は過去のリターンがプラス(マイナス)ならプラス(マイナス)の予想リターンを示す。過去の価格推移を参照して投資判断を行うテクニカル投資家の成分であり、 $r_{h,j}^t$ は時刻 t にエージェント j が計測した過去リターンであり、 $r_{h,j}^t = \log(p^t / p^{t-1})$ 、第3項目はノイズを表している。

予想リターン $r_{e,j}^t$ より予測価格 $P_{e,j}^t$ は、

$$P_{e,j}^t = P^t \exp(r_{e,j}^t) \quad (2)$$

で求まる。

注文価格 $P_{o,j}^t$ は $P_{e,j}^t - P_d$ から $P_{e,j}^t + P_d$ までの一様

乱数で決める。ここで、 P_d は定数である。そして、売り買いの別は予想価格 $P_{e,j}^t$ と注文価格 $P_{o,j}^t$ の大小

関係で決める。 $P_{e,j}^t > P_{o,j}^t$ なら1単位の買い、

$P_{e,j}^t < P_{o,j}^t$ なら1単位を売り。

また各エージェントが注文を出す直前に学習を行い、学習プロセスに関する部分が以下のようにモデルした。ファンダメンタルな投資家成分だけの場合の予想リターン $r_{e,1,j}^t = \log(p_f / p^t)$ 、テクニカルな投資

家成分だけの場合の予想リターン $r_{e,2,j}^t = r_{h,j}^t$ とする。

これら $r_{e,i,j}^t$ が学習期間のリターン $r_i^t = \log(p^t / p^{t-1})$ と比べ、

$$\text{同符号なら, } w_{i,j} \leftarrow w_{i,j} + k_i r_i^t \rho_j^t (w_{i,\max} - w_{i,j}) \quad (3)$$

$$\text{異符号なら, } w_{i,j} \leftarrow w_{i,j} - k_i r_i^t \rho_j^t w_{i,j} \quad (4)$$

のように、 $w_{i,j,k}$ を書き換える。このような過去の実績から学習するプロセスとは別に、小さい確率 m で $w_{i,j,k}$ を再設定する。

1.2 集団行動バイアスモデル

集団行動バイアスは、きちんと知識を持っていたとしても、正しい行動がとれるとは限らない。周りの人の言葉や雰囲気によって、本来とるべき、適切な行動が取れないことが知られている。集団行動バイアスを持ちエージェントが投資行動を行う時自分の知識より行動だけではなく、他人の行動も観測している。そこで、集団行動バイアスを持つエージェントは、閾値によって他のエージェントの行動を考慮して最終行動を行う。

具体的に以下のプロセスで意思決定する：

1. 自己信号：時間 t の時、ベースモデルのアルゴリズムで1単位を買うか売るか判断する。予想価格 $>(<)$ 注文価格なら、1単位を買う(売る)。

2. 他者信号：時間 t の時、前の H_t (ここは $H_t=1$)内行動したすべてのエージェントが買うか売るかを観測し、式(5)(6)を計算する。

$$r_{buy}^t = N_{buy}^t / N_{total}^t \quad (5)$$

$$r_{sell}^t = N_{sell}^t / N_{total}^t \quad (6)$$

3. 自己信号と他者信号を比較して、自己信号と異

なる他者信号の比率が閾値 θ ($\theta > 0.5$) を超えるなら、自己信号を無視し、他者の行動をフォローする。つまり、自己信号買い(売る)が、他者信号 r_{sell}^t (r_{buy}^t) $> \theta$ なら、最終行動を売りとする

3. シミュレーション結果

本研究で 1000 人のエージェントを設定し、10 回試行の平均値を用い、測定期間は 100 ステップ間隔とした。シミュレーションのパラメータを以下のように与える。

- エージェント数: $n = 1000$
- 終了時刻: $t_{max} = 5000$
- ファンダメンタルウェイト最大値: $w_{1,max} = 1$
- テクニカルウェイト最大値: $w_{2,max} = 10$
- ノイズ: $w_{3,max} = 1$
- ファンダメンタルプライス: $P_f = 10000$
- 発注可能な上下限: $P_d = 1000$
- 注文をキャンセル時間: $t_c = 10000$
- 最大の投資期間: $\tau_{max} = 10000$.

3.1 妥当性検証

まずモデルの妥当性検証を行った。表 1 のように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 といった代表的な stylized fact が再現できることを確認した。

表 1: 集団行動エージェント率が異なる場合の統計量

集団行動エージェント	0	0.5	1
尖度	1.9547292	2.0064914	56.5300079
勝落率の			
1	0.1208304	0.1235468	0.1100038
2	0.0943034	0.0925828	0.0494043
乗の			
2	0.0746802	0.0708542	0.0328181
の自			
3	0.0575658	0.0555178	0.0277776
己相			
4	0.0487210	0.0474510	0.0247603
関			
5	0.0416219	0.0392829	0.0225208

また、本研究では、集団行動バイアスを持つエージェントの比率の増加或いは集団行動を取る基準の低下による全体的な集団行動が大きくなる効果を検証するため、herding intensity を用いて集団行動バイアスの妥当性を証明した。

Buy(sell)herding intensity = herding buys(sells) / informed trades.

結果は 10 回試行の平均値を用いて図 1 と図 2 に示す。X 軸は集団行動バイアスエージェントが設定

した閾値で、自分の行動とは異なるエージェントが閾値を超える場合他人の行動をフォローする。Y 軸は集団行動バイアスを持つエージェントが全体エージェントに占める比率、Z 軸は集団行動密度である。

設定した閾値が低いほど集団行動が増加する。また集団行動バイアスを持ちエージェント比率が増やす共に集団行動が増加することが示された。

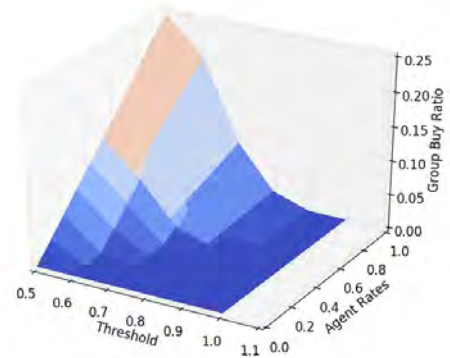


図 1: 集団行動の基準と集団行動 (buy) の関係




図 2: 集団行動の基準と集団行動 (sell) の関係

3.2 集団行動バイアスが市場への影響

尖度、ボラティリティ及び市場の効率性の三つの方面から集団行動バイアスが市場へ与える影響を測定した。




図 3: 閾値と尖度




図 4: 閾値とボラティリティ

図 3, 図 4 は全てのエージェントが集団行動バイアスエージェントであると設定し, 各エージェントが設定した閾値(>0.5)と尖度, ボラティリティの関係を示した. 両方によると, 閾値が 0.7 より小さい時から尖度, ボラティリティが高まる. 一方で閾値が 0.7 より大きい時, ボラティリティがほぼ一定である.

また市場の効率性を直接測定する指標として, 人を用いた実験市場研究でしばしば用いられる市場非効率性 MI (Market Impact) を用いる. n_b は集団行動バイアスエージェントの注文数で, P_b^j は注文成立の価格, P_f はファンダメンタル価格 MI の値が大きい程市場への影響度が大きい.

$$MI = \frac{1}{n_b} \sum_{j=1}^{n_b} \frac{P_b^j - P_f}{P_f} \quad (5)$$

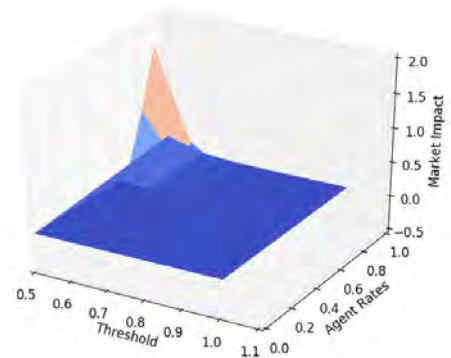


図 5: 集団行動バイアスと MI の関係

図 5 は, X 軸が集団行動バイアスエージェントが設定した閾値を, Y 軸は集団行動バイアスを持つエージェントが全体エージェントに占める比率を, Z 軸は市場非効率性を表す指標を示している. 集団行動バイアスによって投資家の行動が非合理となり, その結果市場が非効率的となることが明らかとなった.

4. まとめと今後の課題

本研究では, 水田ら[7]の人工市場モデルをベースに一般モデルと集団行動バイアスを表現するモデルを組み合わせ, 集団行動バイアスが市場に与える影響を分析した. 具体的には, 集団行動バイアス持ちエージェントの比率と集団行動バイアスエージェントが集団行動を取る可能性の二つの軸から価格変動に与える影響を展開した. 集団行動バイアスによって投資家の行動は非合理的であり, その結果市場は非効率であることを明らかにした. また, 70%以上の人が自分と異なる行動を取る時他人にフォローする場合, 市場への影響を大きくされないと考えられる.

今後の課題として, ニューヨーク, 東京, ロンドン三つの実為替市場を対象として, 別々の集団行動特徴を抽出し, 各市場の変動特性を解明する事がある.

参考文献

- [1] 翟菲. "人工市場モデルを用いた投資家心理的バイアスの株式市場への影響評価について." (2012).
- [2] Consistency of Risk Attitude and other Investment Behavior of Japanese Fund Managers, M. Susai and S. Uchida (eds.), Studies on Financial Markets in East Asia,

January 2011

- [3] Avery, Christopher, and Peter Zemsky. "Multidimensional uncertainty and herd behavior in financial markets." *American economic review* (1998): 724-748.
- [4] Jurkatis, Simon, Stephanie Kremer, and Dieter Nautz. *Correlated trades and herd behavior in the stock market*. No. 2012-035. SFB 649 Discussion Paper, 2012.
- [5] Jurkatis, Simon, Stephanie Kremer, and Dieter Nautz. *Correlated trades and herd behavior in the stock market*. No. 2012-035. SFB 649 Discussion Paper, 2012.
- [6] S. -H. Chen, C. -L. Chang, and Y. -R. Du, "Agent-based economic models and econometrics," *Knowledge Engineering Review*, vol. 27, no. 2, pp. 187–219, 2012.
- [7] Mizuta, Takanobu, et al. "Do dark pools stabilize markets and reduce market impacts? Investigations using multi-agent simulations." *Computational Intelligence for Financial Engineering & Economics (CIFEr), 2104 IEEE Conference on*. IEEE, 2014.

マーケットメーカーがダーク・プールの存在する市場の 効率性に与える影響：人工市場アプローチによる分析

Impact of Market Maker to Efficiency of Stock Market with Dark Pool - Artificial Market Approach

西岡伸¹ 鳥居拓馬² 和泉潔²

Shin Nishioka¹, Takuma Torii², and Kiyoshi Izumi²

¹ 東京大学工学部システム創成学科

¹ Department of Systems Innovation, Faculty of Engineering, The University of Tokyo

² 東京大学大学院 工学系研究科

² School of Engineering, The University of Tokyo

Abstract: In this research, we analyzed impact on market efficiency of interaction between high frequency trading (HFT) and dark pool to a stock market using artificial market simulation. We introduced a market maker agent, a representative strategy of HFT, and changed its spread for order price. We also changed each stylized trader agents' percentage to use dark pool. The result showed that the smaller the spread of the market maker is, the more efficient the stock market becomes. We discussed the mechanism that percentage to use dark pool have a different impact to the efficiency of the market depending on the size of the market maker's spread.

1. はじめに

現在、高頻度取引（HFT）が株価や外国為替などの金融価格の安定性に与える影響が大きな議論の対象となっている[1]。他方で、ダーク・プールと呼ばれる、通常の取引所を通さずに投資家の注文同士を証券会社内で付け合わせる取引市場がシェアを高めつつある[2]。

現実の金融市場はさまざまな要因が複雑な相互作用をもち、関心のある要因だけを取り上げて分析することが難しい。そこで、計算機上に仮想的な金融市場のモデルを構築し分析する人工市場シミュレーションが行われている[3]。

人工市場を用いた既存研究では、HFTの影響のみ[4]、ダーク・プールの影響のみ[5]について個別に分析されている。ところが、高頻度取引とダーク・プールの両方が存在する市場については、人工市場を用いた分析はない。そこで、本研究では、高頻度取引とダーク・プールの相互作用が市場に及ぼす影響を明らかにすることを目的とし、人工市場シミュレーションを行った。

2. 人工市場モデル

本研究のモデルでは先行研究[6][7]をベースに、1つのリット市場（通常の取引所）に加えて、それに対応した1つのダーク・プール市場が存在する状況を扱う。また、 n 体のスタイライズドトレーダー（標準の取引エージェント）に加えて1体のマーケットメーカー（高頻度取引エージェント）が取引を行う。シミュレーションの各ステップ t では（図1）、まず、無作為に選ばれたスタイライズドトレーダー1体がリット市場あるいはダーク・プールに注文を出す。次に、マーケットメーカーがリット市場に売り買い両方の注文を出す。このステップを繰り返し行い、ダーク・プールの取引頻度（図1、パラメータ d ）とマーケットメーカーの利益率（図1、パラメータ θ ）が以下に定義する市場非効率性の指標に与える影響を調べる。

2.1 リット市場

リット市場の取引は連続ダブルオークション（ザラバ方式）に従う。リット市場では、価格優先・時間優先の原則に従い、相対する注文と突き合わせら

れ取引が生じる。ただし、約定しなかった注文は板に蓄積される。価格時系列のほか、売り板、買い板に対応した最高買い気配値（ベストビッド）、最安売り気配値（ベストアスク）、またその平均値である仲値といった情報をトレーダーは利用できる（この点でダーク・プールと異なる）。リット市場の価格 P_{lit}^t は、価格の変化幅の最小単位であるティックサイズ $\delta P = 0.1$ より細かい値段では取引されず、それより小さい端数は、買い注文の場合は切り捨て、売り注文の場合は切り上げる。

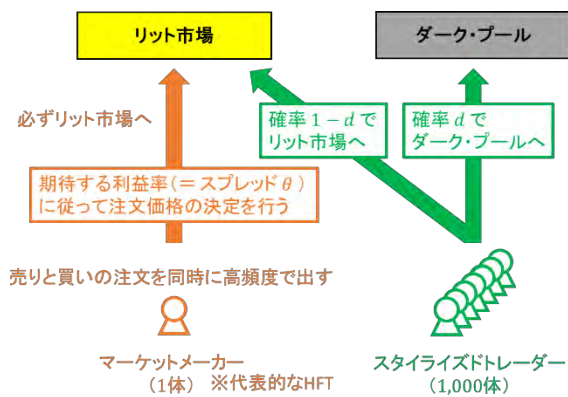


図 1 各ステップにおけるモデル全体の振る舞い

2.2 ダーク・プール

リット市場と対照的に、ダーク・プールでは取引価格や板の状態といった情報をトレーダーは利用できない。また、ダーク・プールに注文を出す際、トレーダーは価格を指定せず、反対側の注文がダーク・プール市場にある場合は即座に取引が成立し、取引価格は自動的にリット市場の仲値となる（図 2）。このように価格が自動的に決まり、相対する注文があれば即座に約定が起きるため、ダーク・プールでは必ず売り板か買い板の一方にしか注文が残らない。




図 2 ダーク・プールにおける注文処理

2.3 スタイライズドトレーダー

本モデルでの標準的な取引エージェントであるスタイライズドトレーダー[5]は、リット市場の情報をもとに将来の予想価格を見積もり、注文価格を決定したのち、確率 $1-d$ でリット市場を、確率 d でダーク・プールに注文を出す。

まず、スタイライズドトレーダー j はファンダメンタル分析とチャート分析を行い、これらの分析結果とノイズの加重平均として、式(1)で予想リターン $r_{e,j}^t$ を見積もる。

$$r_{e,j}^t = \frac{w_{F,j}F_j^t + w_{C,j}C_j^t + w_{N,j}N_j^t}{w_{F,j} + w_{C,j} + w_{N,j}} \quad (1)$$

ここで、 $F_j^t = \log(P_f/P_{lit}^t)$ はファンダメンタル分析の成分を表し、現在のリット市場の価格 P_{lit}^t とファンダメンタル価格 P_f との乖離に基づく。また、 $C_j^t = \log(P_{lit}^t/P_{lit}^{t-\tau_j})$ はチャート分析の成分を表し、過去 τ_j 期間に渡るリターン時系列のトレンドに基づく。最後に、 $N_j^t \sim N(0, \sigma_\epsilon)$ は平均 0、標準偏差 σ_ϵ の正規分布に従ったランダムな成分である。 $w_{F,j}$ 、 $w_{C,j}$ 、 $w_{N,j}$ はそれぞれ各成分への重みである。上式の予想リターンから、予想価格を式(2)で見積もる。

$$P_{e,j}^t = P_{lit}^t \exp(r_{e,j}^t) \quad (2)$$

注文価格 $P_{e,j}^t \sim N(P_{e,j}^t, P_\sigma)$ は、平均 $P_{e,j}^t$ 、標準偏差 P_σ の正規乱数で決める。売り買いの別は、予想価格と注文価格の大小関係によって決定し、 $P_{e,j}^t > P_{o,j}^t$ のとき 1 単位の売り注文を、 $P_{e,j}^t < P_{o,j}^t$ のとき 1 単位の買い注文を出す。注文は t_c^{st} ステップのうちに約定しなければキャンセルされる。

2.4 マーケットメーカー

本モデルでは HFT の代表的な取引戦略の一つであるマーケットメーカー (MM) を導入した。MM[4] はスタイライズドトレーダー 1 体が 1 回注文を出すごとに 1 回注文を出す機会をもち、この点で各スタイライズドトレーダーの n 倍高頻度で取引を行う。MM は、必ずリット市場を選択し、リット市場の仲値の上下に等間隔で売り注文と買い注文を 1 単位ずつ出す（図 3）。この間隔は MM のスプレッド（利益率） θ とファンダメンタル価格 P_f に依存し、 $(P_f \times \theta)/2$ とした[4]。MM は注文を出す前に以前の注文をキャンセルする。

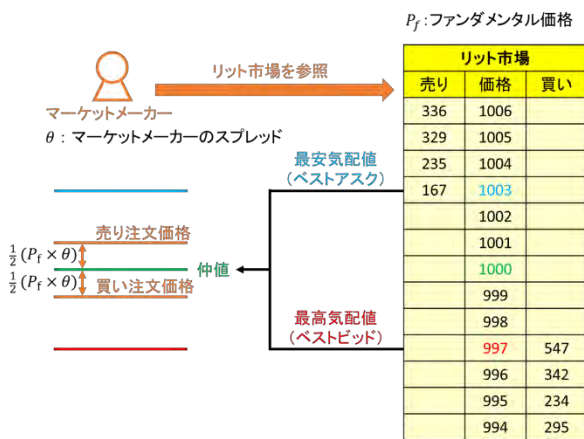


図 3 マーケットメーカーの注文価格の決定方法

2.5 市場非効率性

本研究では、高頻度取引とダーク・プールの相互作用が市場に及ぼす影響を明らかにするため、ダーク・プール利用率 d とマーケットメーカー (MM) のスプレッド θ が市場の効率性に与える影響を分析する。そこで、本論文では、価格発見機能の観点から水田ら [5] の定義した市場の非効率性を特徴づける指標である式 (3) を用いた。

$$M_{ie} = \frac{1}{T} \sum_{t=t_s}^T \frac{|Q^t - P_f|}{P_f} \quad (3)$$

M_{ie} はファンダメンタル価格 P_f からの平均的な乖離を表し、大きいほど非効率となる。ここで、 Q^t は、2 つの市場の効率性を同時に特徴づけるため、ある時点 t でダーク・プールで取引があった場合は仲値を、そうではなくリット市場で取引があった場合はその価格を用いた。以降、本論文では Q^t を取引価格と呼ぶ。

3. シミュレーション結果

本研究では、 d と θ 以外のパラメータの値として、 $n = 1000$, $t_c^{st} = 2000$, $\sigma_\epsilon = 0.06$, $P_\sigma = 30$, $P_f = 10000$, $\delta P = 0.1$ を共通の定数とし、 $w_{F,j} \in [0, 1]$, $w_{C,j} \in [0, 5]$, $w_{N,j} \in [0, 1]$, $\tau_j \in [1, 1000]$ を一様分布乱数で与えた¹。これらの値は水田ら [5] を参考にして定めたが、水田ら [5] では、 $w_{C,j} \in [0, 10]$, $\tau_j \in [1, 10000]$ としている点が異なる。シミュレーション開始後の 1000 ステップは市場が開く前の状態とし、

¹ パラメータの妥当性を検証するため、ダーク・プールなし、MM なしのシミュレーションを行い、価格時系列の統計的性質を調べた結果、1 日の約定率が東証の平均約定率とおおむね一致

$t = t_s = 1000$ から注文処理を開始する。その後の 40000 ステップの全期間の価格時系列を用いて市場非効率性 M_{ie} を計算した。

3.1 d と θ が市場効率性に与える影響

図 4 は、さまざまなスプレッド θ において、ダーク・プール利用率 d を変化させたときに非効率性 M_{ie} がどう変化するかを示す。シミュレーションは各 (d, θ) の組合せに対して各 30 回ずつ行い、その平均を示した。全体的な傾向として、 θ が小さいほど非効率性は減少している。図から、マーケットメーカー (MM) なしの場合、グラフは下に凸の形状を示し、 $d = 0.5$ 付近で非効率性は最も低くなり、 $d = 0.9$ 付近では再度上昇している。MM ありの場合、 θ の大きさによって、 d の変化がもたらす市場非効率性への影響が異なる。まず、 θ が極端に大きい場合 ($\theta = 1\%$)、MM の取引は価格時系列に影響を及ぼさず、グラフは MM なしのとほぼ一致する。他方、 θ が大きいときでは ($\theta = 0.316\%, 0.1\%$)、 d が大きくなるほど非効率性は増加する。一方で、 θ が小さいときでは ($\theta = 0.01\%, 0.001\%$)、 d が大きくなるほど非効率性は減少するが、その変化の大きさは θ が大きいときに比べてわずかであった。特に、 θ とティックサイズ δP が一致する場合には ($\theta = 0.001\%$)、 d に依らず非効率性はほぼゼロとなる。




図 4 ダーク・プールへの配分比率ごとの市場非効率性

し、騰落率の尖度が正、騰落率の 2 乗の自己相関が正になることを確認した。

以上から、MM がいる場合、MM がいない場合に比べて市場は効率的になる傾向がある。また、MM の影響が小さい場合 (MM なし, $\theta = 1\%$) には、ダーク・プールのある程度までの利用によって市場は効率化するのに対し、MM の影響が大きい場合 ($\theta \leq 0.316\%$) には、ダーク・プールの利用率が高まるほどに市場は非効率になる可能性が示唆される。次節以降では、 d と θ が市場効率性に与える影響を探るため、図 4 から代表的な点 (d, θ) をとりあげ、その詳細を見ていく。

3.2 マーケットメーカーの影響

まず、ベースラインとなる結果として、ダーク・プールを使用せず ($d = 0.0$)、またマーケットメーカーのスプレッドが十分に大きく ($\theta = 1\%$) 市場への影響が小さい場合の取引価格 Q^t の時系列を図 5 に示す。図中、黒線は取引価格 Q^t を、赤線はベストビッド、青線はベストアスクを、それぞれ表す (以下他の時系列の図についても同様)。図中、取引価格 Q^t はファンダメンタル価格 $P_f = 10000$ の周辺を変動している。他方、図 6 は、ダーク・プール利用率 $d = 0.0$ は同じで、マーケットメーカーのスプレッドを 10 分の 1 ($\theta = 0.1\%$) に変化させたときの価格時系列である。 $\theta = 1\%$ のとき (図 5) に比べ、 0.1% のとき (図 6) の方が、価格の変動幅が狭くなっている。実際、他の θ の値においても、 θ が小さくなるほど価格の変動幅は狭くなることが観察される。これはスタライズドトレーダーの注文がマーケットメーカーの注文と約定するため、スプレッドが実質的な価格の変動幅を制限しているためだと考えられる。このことから、マーケットメーカーのスプレッドが小さいほど、価格の変動幅が狭くなることが分かる。

3.3 ダーク・プール利用率の影響

次に、マーケットメーカーのスプレッド θ の大きさごとに、ダーク・プール利用率を変化させた場合の影響を調べる。図 7 は、図 6 ($d = 0.0, \theta = 0.1\%$) の一部を縦方向に (価格の範囲を) 拡大したものである。他方、図 8 は、 $d = 0.9, \theta = 0.1\%$ のときの価格時系列である。これらと比較すると、ダーク・プール利用率が高くなると、取引価格のファンダメンタル価格からの乖離の最大値が大きくなる傾向や、長期間的な乖離が起きやすくなる傾向がみられる。このことから、ダーク・プール利用率が大きくなると、取引価格のファンダメンタル価格からの乖離は上記の 2 つの点で大きくなることが見られた。




図 5 $d = 0.0, \theta = 1\%$ のときの価格時系列




図 6 $d = 0.0, \theta = 0.1\%$ のときの価格時系列




図 7 図 6 ($d = 0.0, \theta = 0.1\%$ のときの価格時系列) を縦軸 (価格) 方向に拡大したもの

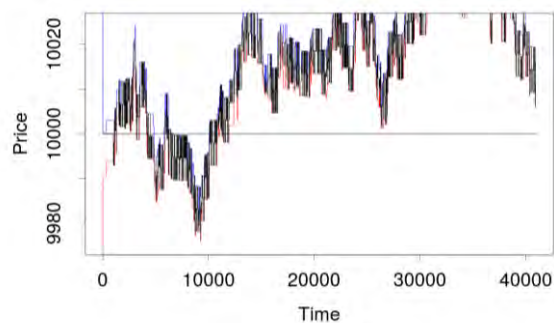


図 8 $d = 0.9, \theta = 0.1\%$ のときの価格時系列

4. 議論

本論文の結果では、マーケットメーカー (MM) の影響が小さい場合、ダーク・プール利用率が大きくなると、あるところまでは市場非効率性は減少し、それ以降は逆に増加して、全体としてグラフは下に凸の形状を示した。また、マーケットメーカーの影響が大きい場合、ダーク・プール利用率が大きくなるほど、市場非効率性のグラフが右肩上がりとなることが観察された。本節では、これらの代表的な結果について、そのメカニズムを考察する。

水田ら [5] は、ダーク・プールが市場を効率化するメカニズムについて、仲値を用いた取引価格によってビッド・アスク・バウンスが低減されるためであると論じている。しかし、このメカニズムが成立するには、ベストビッドとベストアスクの間にファンダメンタル価格が挟まれていることが前提となる。そのため、ファンダメンタル価格がベストビッドとベストアスクの間にある場合 (両側状態、以下で定義) と、ファンダメンタル価格がベストビッドとベストアスクの外にある場合 (片側状態、以下で定義) を区別する必要がある。本論文では、両側状態と片側状態の区別を導入し、水田によるメカニズムの記述をより詳細に分析し論じるとともに、マーケットメーカーの介入により生じる効果を論じる。より具体的には、以降では、以下に述べる市場の効率性に関する 3 つの効果の重ね合わせによって、図 4 に見られる、下に凸の形状および、単調増加の形状を説明する。

4.1 マーケットメーカーの影響が小さい場合




図 9 ビッド・アスク・バウンスの低減が市場を効率的にする様子 (水田ら [5] からの引用)

水田ら [5] は、ダーク・プールの利用率が高まると、図 9 のようにビッド・アスク・バウンスの低減が市場を効率的にすると主張している。ここで、ビッド・

アスク・バウンスとは、取引価格がベストアスクとベストビッドの間を何度も頻繁に往復する現象のことを言う。

しかし、この主張が成り立つのは、ベストビッドとベストアスクの間にファンダメンタル価格が挟まれているときのみである。図 10 では、価格時系列を市場価格同士的位置関係によって 2 つの状態に分類した様子を模式的に表している。図中、黄色はファンダメンタル価格 P_f 、青色はベストアスク、赤色はベストビッド、緑色は仲値、黒色は取引価格 Q^t を表す。左側の図では、ベストビッドとベストアスクの間にファンダメンタル価格が挟まれており、本研究ではこのような状態を両側状態と呼ぶ。他方、右側の価格時系列では、ベストビッドとベストアスクの外側にファンダメンタル価格があり、本研究ではこのような状態を片側状態と呼ぶ。

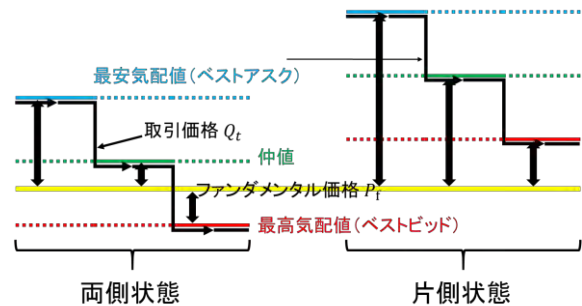


図 10 両側状態と片側状態

図 10 において、両側状態では、ベストアスクとベストビッドそれぞれのファンダメンタル価格からの乖離の平均に比べ、仲値のファンダメンタル価格からの乖離は小さい。よって、両側状態では、ダーク・プール利用率が大きくなるほど取引価格のファンダメンタル価格からの乖離が小さくなり、市場は効率的になる。これは、水田ら [5] の主張が成り立つ場合である。一方で、片側状態ではベストアスクとベストビッドそれぞれのファンダメンタル価格からの乖離の平均は、仲値のファンダメンタル価格からの乖離と一致する。すなわち、片側状態では、ダーク・プール利用率が大きくなり、ビッド・アスク・バウンスが低減しても市場を効率的にする効果を持たない。このため、片側状態では水田ら [5] の主張は成り立たない。

次に、ダーク・プール利用率の増大が市場を非効率にする効果ももたらすことを述べる。ダーク・プール利用率が大きくなると、リット市場で取引が行われる頻度が小さくなり、リット市場の板に貯まる注文の数が減る。その結果、数回の注文でベストア

スクやベストビッドが大きく変動することが起きやすくなる。すると、取引価格のファンダメンタル価格からの乖離が大きくなり、市場は非効率になる。

以上から、MMなしの場合、ダーク・プール利用率の増大に伴って、上に述べたような相反する2つの効果、すなわち、市場を効率的にする効果と非効率にする効果がもたらされると考えられる。これらの効果が拮抗することで、図4のMMなしのグラフにおいて、下に凸の形状が現れたと考えられる。

4.2 マーケットメーカーの影響が大きい場合

マーケットメーカー (MM) の影響が大きい場合には、4.1節で述べたようなMMの影響が小さい場合にもたらされる効果に加えて、MMによる市場を非効率にする効果が加わると考えられる。MMは、常に高頻度で仲値の上下一定の幅のところに注文を出す。これによってMMの影響が大きい場合には仲値の上下に壁ができていくような状態となり、図6のように価格の変動幅が制限される。それと同時に、一旦ファンダメンタル価格から乖離してしまうと、MMによる壁によってファンダメンタル価格への回帰が妨げられる。この回帰を妨げる効果は、ダーク・プール利用率が高まり、取引価格がファンダメンタル価格から大きく乖離しやすいほど生じやすい。そのため、図8 ($d = 0.9$) の $t = 15000$ から $t = 40000$ のように、片側状態が持続する期間が現れ、市場が非効率になると考えられる。

MMがいる場合には、MMなしの場合にもたらされる2つの効果に加えて、今述べたようなダーク・プール利用率の増大に伴って市場が非効率になる効果が生じると考えられる。そのため、全ての効果の重ね合わせとして見たときに市場を非効率にする効果の方が大きくなり、図4の $\theta = 0.316\%$, 0.1% のグラフにおいて、右肩上がりの形状が現れたと考えられる。

4.3 先行研究の知見との比較

最後に、本研究のMMなしの場合と水田ら[5]との結果の相違点について、その原因を考察する。3節で述べたように、本研究では水田ら[5]に比べてテクニカル分析の成分の重み $w_{c,j}$ の最大値が小さくなっている。そのため、相対的にノイズ成分の割合が大きくなっている。これによって、上述した、数回の注文でベストアスクやベストビッドが大きく変動する現象がより起きやすくなると思われる。そのた

め、ダーク・プール利用率の増大に伴い、市場を非効率にする効果の方が支配的になり、ダーク・プール利用率 d が 0.5 以上では市場非効率性 M_{ie} は増加したと考えられる。一方、水田ら[5]では逆に、ノイズ成分が相対的に小さいため、両側状態の期間が長くなり、市場を効率的にする効果が支配的となって市場非効率性のグラフは単調減少したものと考えられる。

5. 今後の課題

本研究では、両側状態と片側状態の区別を導入することによって、マーケットメーカーとダーク・プールの相互作用が市場の効率性に与える影響を分析し、そのメカニズムを論じた。しかし、両側状態と片側状態の成立に影響する要因は今回明らかにできていない。今後、それらの要因を明らかにしていく必要がある。また、本研究では、マーケットメーカーが資産運用を考慮せず注文の意思決定を行うようなモデルとなっており、この点において現実的でない。そのため、今後草田ら[4]によるマーケットメーカー戦略を参考にモデルを拡張していく予定である。これらの改善によって、市場の制度設計やトレーダーの投資計画に貢献できるであろう。

参考文献

- [1] マイケル・ルイス 著、渡会圭子、東江一紀 訳：フラッシュ・ボーイズ、文藝春秋、(2014)
- [2] スコット・パターソン 著、永野直美 訳：ウォール街のアルゴリズム戦争、日経BP社、(2015)
- [3] 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)
- [4] 草田裕紀、水田孝信、早川聡、和泉潔：保有資産を考慮したマーケットメイク戦略が取引所間競争に与える影響、人工知能学会論文誌、Vol. 30, No. 5, pp. 675-682, (2015)
- [5] 水田孝信、小杉信太郎、楠本拓矢、松本渉、和泉潔：ダーク・プールが市場効率性と価格発見メカニズムに与える影響、第14回金融情報学研究会予稿集、SIG-FIN-014-02, (2015)
- [6] Chiarella, C. and Iori, G.: A Simulation Analysis of the Microstructure of Double Auction Markets, Quantitative Finance, Vol.2, pp.346-353, (2002)
- [7] Torii, T., Kamada, T., Izumi, K., Yamada, K.: Platform Design for Large-Scale Artificial Market Simulation and Preliminary Evaluation on the K computer, Proceedings of The 21st International Symposium on Artificial Life and Robotics (AROB 21st 2016), OS10-2, pp.1-6, (2016)

人工市場を用いた分散投資規制が資産価格急落時の市場に与える影響の解明

Investigation of the rule for investment diversification at the time of a market crash using an artificial market

野崎 淳^{1*} 水田 孝信² 八木 勲³
Atsushi Nozaki¹ Takanobu Mizuta² Isao Yagi³

¹ 神奈川工科大学大学院情報工学専攻

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

³ Faculty of Information Technology, Kanagawa Institute of Technology

Abstract: 投資信託の取引において、投資家が想定外のリスクを負うのを未然に防ぐため、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。分散投資規制は、1つの発行体への投資が過度に集中しないよう、1つの発行体への投資額を投資信託純資産の一定割合以下にするものである。分散投資の是非についてはこれまでに多くの実証研究がなされているが、分散投資に制約が設けられることによって市場の価格形成にどのような影響が与えられるか議論されたことはない。そこで、本研究では、分散投資規制が資産価格急落時の市場に与える影響を、人工市場を用いて分析した。その結果、一方のリスク資産のファンダメンタル価格が急落した時、市場価格がオーバーシュートし、もう一方のリスク資産の市場価格も連動して下落することが確認できた。

1 はじめに

近年金融商品の複雑化やリスクの複合化により、投資家がリスクを把握しにくくなっている。例えば、投資信託において、投資先資産のバリエーションは広がってきたが、ある特定の資産にリスクが集中しているかもしれない。また、ある投資信託の運用成績は、保有している特定の資産（例えばデリバティブ）の運用成績に大きく依存しているかもしれない。このような状況を投資家がすべて把握することは不可能である。

投資家が想定外のリスクを負うのを未然に防ぐため、投資信託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ている。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 [1][2]。

分散投資規制は、1つの発行体への投資が過度に集中しないよう、1つの発行体への投資額を投資信託純

資産の一定割合以下にするもので、欧州では既に同様の規制が適用されている。例えば、ある投資信託が特定の発行体への、1) 株式、2) 株式を原資産とするオプション、3) 社債に投資していた場合、それぞれの投資額はファンド純資産の10%以下、かつ、これらの合計投資額が投資信託純資産の20%以下とすることが求められている。ここで言う発行体とは、債券の発行元のことであり、株式や債券などの有価証券を投資家に売る企業、政府、金融機関などがそれに当たる。

分散投資そのものの是非についてはこれまでに多くの実証研究がなされている。例えば、Cremersらは分散投資しない方がポートフォリオの運用成績はよいことを示している [3]。一方、分散投資に制約を設けることによって市場の価格形成にどのような影響を与えるかは、これまで議論されたことはない。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であるからである。

このように特定の取引が市場に与える影響を分析す

*連絡先：神奈川工科大学大学院情報工学専攻
神奈川県厚木市下荻野 1030
E-mail:s1585027@ccy.kanagawa-it.ac.jp

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 [4][5][6]。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、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である。

これまでに野崎ら [7] は、人工市場を用いて分散投資規制が市場に与える影響について検証した。その結果、価格推移にはあまり違いは見られず、規制が厳しくなるに従い出来高が減少し、リスク資産の保有リスクが抑えられることが確認された。しかし、野崎らの人工市場モデルは、規制に違反した場合追加の注文を禁止するだけであったが、現実では規制に違反した状態を解消するための取引も行うと考えられる。また、野崎らの研究はファンダメンタル価格が一定の状態での検証であった。

そこで本研究では、金融危機等で資産価格が急落したとき、分散投資規制が市場にどのような影響を与えるのかを、人工市場を用いて分析した。

本論文の構成は以下の通りである。まず、2章にて、本研究で使用する人工市場モデルを説明する。そして、3章では、平常時の相当するファンダメンタル一定の場合と金融危機時に相当するファンダメンタル急落の場合での実験とその結果を示す。4章ではまとめと今後の課題を記す。

2 人工市場モデル

2.1 注文プロセス

本研究では、水田らの人工市場モデル [8] をベースに、モデルを構築した。

本モデルは2つのリスク資産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。 n のエージェントがおり、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、

$$r_{e,j,k}^t = \frac{1}{w_{1,j,k} + w_{2,j,k} + u_{j,k} + w_{2,j,k} r_{h,j,k}^t + u_{j,k} \epsilon_{j,k}^t} (w_{1,j,k} \log \frac{P_{f,k}}{P_k^t} + w_{2,j,k} r_{h,j,k}^t + u_{j,k} \epsilon_{j,k}^t) \quad (1)$$

ここで、 $w_{1,j,k}$ は時刻 t 、エージェント j 、リスク資産 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。また、後で述べる学習過程により変化する。 $u_{j,k}$ は時刻 t 、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時に、それぞれ0から u_{max} まで一様乱数で決め、その後も一定である。 $P_{f,k}$ は時間によらず一定の資産 k のファンダメンタル価格、 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 $P_k^2 = P_{f,k}$ とする)、 $\epsilon_{j,k}^t$ 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。 $r_{h,j,k}^t$ は資産 k 、時刻 t にエージェント j が計測した過去リターンで、 $r_{h,j,k}^t = \log(P_k^t / P_k^{t-\tau_j})$ である。ここで、 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。

式(1)の第1項目はファンダメンタル価格と比較して安ければプラスの予想リターンを高めればマイナスの予想リターンを示す、ファンダメンタル価値を参照して投資判断を行うファンダメンタル投資家の成分である。第2項目は過去のリターンがプラス(マイナス)ならプラス(マイナス)の予想リターンを示す、過去の価格推移を参照して投資判断を行うテクニカル投資家の成分であり、第3項目はノイズを表している。

予想リターン $r_{e,j,k}^t$ より予想価格 $P_{e,j,k}^t$ は、

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

で求まる。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、売り買いの別は予想価格 $P_{e,j,k}^t$ と注文価格 $P_{o,j,k}^t$ の大小関係で決まる。

$$\begin{aligned} P_{e,j,k}^t > P_{o,j,k}^t &\text{なら1単位の買い} \\ P_{e,j,k}^t < P_{o,j,k}^t &\text{なら1単位の売り} \end{aligned} \quad (3)$$

注文数は常に1と一定とする。

各エージェントは、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い、分散投資規制を導入している場合はその判定も行う。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。制約および規制を満たしている場合のみ注文を出し、満たしていない場合は注文を出さない。

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、注文価格より安い(高い)注

文が既に存在すれば、最も安い(高い)売り(買い)注文と即座に取引が成立する。また、約定できる注文が市場に無ければ今回の注文を残す。市場に残した注文がキャンセル時間 t_c だけ経過しても取引が成立しなかった場合は、キャンセルされる。

2.2 学習プロセス

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。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。ファンダメンタルな投資家成分だけの場合の予想リターンを $r_{e,1,j,k}^t = \log(P_k^t/P_k^t)$ 、テクニカルな投資家成分だけの場合の予想リターンを $r_{e,2,j,k}^t = r_{h,j,k}^t$ とする ($k = 1, 2$)。これら $r_{e,i,j,k}^t$ が資産 k の学習期間のリターン $r_{l,k}^t = \log(P_k^t/P_k^{t-t_l})$ と比べ、

$$\begin{aligned} \text{同符号なら, } w_{i,j,k} &\leftarrow w_{i,j,k} + k_l r_l^t p_j^t (w_{i,max} - w_{i,j,k}) \\ \text{異符号なら, } w_{i,j,k} &\leftarrow w_{i,j,k} - k_l r_l^t p_j^t w_{i,j,k} \end{aligned} \quad (4)$$

のように、 $w_{i,j,k}$ を書き換える。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。

このような過去の実績から学習するプロセスとは別に、小さい確率 m で $w_{i,j,k}$ 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 規制のモデル化

本モデルでは、レバレッジ制約と分散投資規制を実装している。レバレッジ制約を次のようにモデル化する。

$$\sum_{j=1}^k |P_j^t \times S_{i,j}^t| \leq v \times NAV_i^t \quad (5)$$

ここで、 $S_{i,j}^t$ は、時刻 t におけるエージェント i 、資産 j の保有量であり、 $S_{i,j}^t > 0$ なら買い保有している状態、 $S_{i,j}^t < 0$ なら空売りしている状態を表している。 v はレバレッジ比率であり、今回は $v = 1$ とした。 C_i^t は時刻 t におけるエージェント i のキャッシュの保有量を表している。 NAV_i^t は純資産であり、

$$NAV_i^t = \sum_{j=1}^k (P_j^t \times S_{i,j}^t + C_i^t) \quad (6)$$

表 1: パラメータ設定

parameters	value
n	1000
$w_{1,max}$	1
$w_{2,max}$	10
u_{max}	1
τ_{max}	10000
σ_e	0.03
P_d	1000
t_c	10000
k_l	4
m	0.01

である。

次に、分散投資規制を次のようにモデル化する。

$$\frac{|P_j^t \times S_{i,j}^t|}{NAV_i^t} \leq w_{dir} \quad (7)$$

w_{dir} は、分散投資規制の規制比率であり、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値である。

各エージェントは、注文を発注する際、その注文が規制に違反する、つまり、上記の式 (7) を満たさない場合は、その注文をキャンセルする。また、すでに式 (7) に違反している場合は、規制に違反した状態を解消するために 1 単位の成行注文を出す。これ以降上記の注文を規制違反注文と呼び、買い注文の場合は規制違反買い注文、売り注文の場合は規制違反売り注文と呼ぶ。

3 シミュレーション結果

本研究では、パラメータを表 1 のように設定した。シミュレーションは $t = 1000000$ まで行った。

3.1 モデルの妥当性

シミュレーション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 [9]。fat-tail は、市場価格の騰落率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。また、volatility-clustering は市場価格の騰落率の 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。本研究では、実証研究で得られた fat-tail と volatility-clustering が再現できるようにパラメータを調整した。

表 2: 各試行における Stylized Fact

分散投資規制比率	資産 1				資産 2				
	規制なし	0.75	0.5	0.25	規制なし	0.75	0.5	0.25	
尖度	4.72	4.91	5.12	5.87	4.71	4.82	5.42	5.40	
価格騰落率の 2乗の 自己相関	ラグ								
	1	0.12	0.12	0.11	0.09	0.11	0.11	0.12	0.10
	2	0.09	0.10	0.10	0.08	0.10	0.10	0.10	0.08
	3	0.08	0.08	0.08	0.07	0.08	0.07	0.08	0.07
	4	0.06	0.06	0.07	0.06	0.06	0.06	0.07	0.06
	5	0.05	0.06	0.06	0.05	0.05	0.05	0.06	0.04
6	0.05	0.04	0.05	0.05	0.04	0.05	0.05	0.04	

表 2 は 2 つの資産のファンダメンタル価格が一定のとき、分散投資規制が導入されていない場合と導入された場合 ($w_{dir} = 0.75, 0.5, 0.25$) の stylized fact を示している (価格変動等詳細な実験結果は 3.2 節にて示す)。各々の場合について 100 回の試行を行い平均値をとった。stylized fact はすべて 100 ステップ間隔での価格を用いて計算した。というのも、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 stylized fact は多くの価格変動がないデータによりバイアスがかかってしまうため、100 ステップ間隔での測定とした。いずれのシミュレーションでも尖度がプラスの値で fat-tail となっており、騰落率の 2 乗の自己相関もラグが増えてもプラスで volatility-clustering も再現されている。これらにより長期に観測される価格変動の統計的な性質を再現していることが示された。

3.2 資産 1 と 2 のファンダメンタル価格が一定のとき

この節では、資産 1 と 2 のファンダメンタル価格が一定の場合 ($P_{f,1} = P_{f,2} = 10000$) の実験とその結果を示す。初期キャッシュ量 $C_i^0 = 100000$ 、リスク資産の初期保有数 $S_{i,j}^0 = 0$ とした。

図 1 に、分散投資規制を導入していない場合と導入した場合の価格推移を示す。

分散投資規制が導入されていない場合と導入された場合の取引価格は、ファンダメンタル価格を中心に価格が形成され、大きな違いは見られなかった。図は割愛したが、資産 2 も同様の結果となった。

このような結果となった理由については、以下の 2 点が考えられる。まず、価格推移が安定しているために分散投資規制に違反するエージェントが少ないことが挙げられる。各エージェントは分散投資規制に違反すると、規制違反注文が発注する。しかし、規制に違




図 1: 資産 1 のファンダメンタル価格が一定のときの資産 1 の価格推移

反するエージェントが少なければ、発注される規制違反注文の数も少なくなるため、価格に大きな影響を与えないと考えられる。次に、規制違反買い注文と規制違反売り注文が均衡していることが挙げられる。今回の結果では、リスク資産の初期保有数は 0 であり、買い保有している状態で規制に違反するエージェントと、空売りしている状態で規制に違反するエージェントの数が同程度存在し、それらのエージェントによって発注される規制違反売り注文と規制違反買い注文が互いの影響を相殺しているため価格に違いが見られなかったと考えられる。

3.3 資産 1 のファンダメンタル価格が急落するとき

この節では、資産 1 のファンダメンタル価格が急落する場合 ($P_{f,2} = 10000$ 、時刻 $t = 0$ から $t = 100000$ までは $P_{f,1} = 10000$ 、 $t = 100001$ 以降は $P_{f,1} = 7000$) の実験とその結果を示す。この実験では、資産 1 と資産 2 に連動性を持たせるため、初期キャッシュ量 $C_i^0 = 50000$ 、




図 2: 資産 1 のファンダメンタル価格が急落するときの分散投資規制が導入されない場合の価格推移




図 3: 資産 1 のファンダメンタル価格が急落するときの分散投資規制が導入された場合の価格推移

リスク資産の初期保有数 $S_{i,j}^0 = 48$, $w_{dir} = 0.5$ とした。

図 2 に、分散投資規制が導入されていない 2 つの市場において、資産 1 のファンダメンタル価格が急落したときの両市場の価格推移を、図 3 に、分散投資規制が導入されている 2 つの市場において、資産 1 のファンダメンタル価格が急落したときの両市場の価格推移を示す。図 2 と図 3 より、規制が導入されていない場合はファンダメンタル価格が急落した場合でも、資産 1 の市場価格はオーバーシュートすることなく新しいファンダメンタル価格に収束するのにに対し、規制が導入された場合は急落後のファンダメンタル価格をオーバーシュートした後新しいファンダメンタル価格に収束していることが分かる。

この結果の理由は、以下のように考えられる。ファンダメンタル価格が急落した後に取引が行われる中で、板上の資産 1 の買い注文が約定することによって、資産 1 の保有高が増加し、分散投資規制に違反するエー



図 4: 100000 期～200000 期における資産 1 の約定注文数

ジェントが現れる。そのエージェントが規制違反状態を解消するために資産 1 の規制違反売り注文を出すことが、資産 1 の市場価格がオーバーシュートする一因ではないかと考えられる。

この仮説が正しいかどうか検証するため、100000 期から 200000 期までの間にエージェントが新規発注した 3 種類の注文（規制違反売り注文、通常の式 (1) より決定された売り注文および買い注文）の約定数を調査した (図 4)。

図 4 より、ファンダメンタル価格が急落した後、時間の経過に従い規制違反売り注文が増加していることが確認できる。よって、この仮説は妥当ではないかと考えられる。ただし現実的には、ファンダメンタル価格が急落した場合は、板上の買い注文をキャンセルする可能性もあるため、この結果が現実に即したものであるかは断言できない。従って、分散投資規制の対象とならないエージェントも参加させ、それらの注文も板上に残るようにすることが今後の課題として挙げられる。

さらに図 3 から、資産 1 の市場価格の下落に連動するように資産 2 の市場価格も下落し、最終的には 8700 前後の市場価格に収束していることが分かる。

このような結果となった理由は次のように考えられる。まず、資産 1 の価格が急落し始めると、エージェントの純資産は小さくなるため、多くのエージェントの資産 2 の保有高が規制に違反した状態となる。すると、規制違反状態を解消するために数多くのエージェントが規制違反売り注文を出すため、資産 2 の市場価格も下落するものと考えられる。

図 5 を例に考えると、価格急落前の純資産は 1000000、資産 1 と資産 2 の保有高はそれぞれ 500000 で、分散投資規制比率は 50% ($w_{dir} = 0.5$) である。資産 1 の価格



図 5: 価格急落時の規制違反注文を出すまでのメカニズム

が 30% 下落したとき、純資産は 850000 に、資産 1 の保有高は 350000 に減少するのに対し、資産 2 の保有高は変わらないため、純資産に対する資産 2 の保有高が 50% を超えてしまい、分散投資規制に違反する。そのため、規制違反状態を解消するため、75000 の規制違反売り注文を出す。これらの行動を多くのエージェントがとることにより、資産 2 の市場価格が下落すると考えられる。

資産 1 の価格の下落が収まると、資産 2 の規制違反状態も次第に解消される。それに伴い、規制違反売り注文が発注されなくなり、資産 2 の価格の下落が止まる。その後、ファンダメンタル要素の影響を強く受け、資産 2 が割安だと判断し、プラスの予想リターンを出して買い注文が約定するようになり、価格が上昇する。最終的に価格が 8700 前後に収束するのは、上記の買い注文と規制に違反したことによって出される規制違反売り注文の数が均衡するためであると考えられる。

以上の資産 2 の価格推移についての仮説のうち、まず資産 2 の市場価格が資産 1 の市場価格に連動して下落する理由が正しいか検証する。まず、資産 1 のファンダメンタル価格急落直後から資産 2 の価格の下落が収まる期間の、エージェントが新規発注した 3 種類の注文（規制違反売り注文、通常の式 (1) より決定された売り注文および買い注文）の約定数を調査した (図 6)。

図 6 より、資産 1 のファンダメンタル価格が急落した後しばらくの間、大量の資産 2 の規制違反売り注文が約定していることが分かる。ただし、資産 2 の市場価格の下落は約 200000 期まで続くが、規制違反売り注文の約定数は 120000 期をピークに減っているのも分かる。この理由は、資産 2 の保有高が規制違反状態にあったエージェントの多くが、取引が進む中で規制違反状態が解消されたためであると考えられる。また、規制違反売り注文が減った後も資産 2 の市場価格が下落を続けているのは、テクニカル要素の影響を強く受けてマイナスの予想リターンを出して売り注文が約定するようになるからであると考えられる。



図 6: 100000 期～200000 期における資産 2 の約定注文数




図 7: 200000 期～500000 期における資産 2 の約定注文数

次に、資産 2 の市場価格が最終的に 8700 前後に収束する理由が正しいか検証する。資産 2 の市場価格が最低値になった時から価格が収束するまでの期間の、エージェントが新規発注した 3 種類の注文（規制違反売り注文、通常の式 (1) より決定された売り注文および買い注文）の約定数を調査した (図 7)。

図 7 より、資産 2 の取引価格が最低値になった時から価格が安定するまでの期間 (200000 期～300000 期にかけて) と通常の買い注文が売り注文と比較して多い期間がほぼ一致していることが見て取れる。以上の結果より、資産 2 の価格推移についての仮説は正しいと考えられる。ただし、資産 2 の市場価格がファンダメンタル価格よりも安い価格に収束するという結果は現実では見られない可能性が高い。なぜなら、今回の実験では全てのエージェントが分散投資規制を適用されているが、現実の市場では分散投資規制が適用されない投資家も数多く存在するからである。図 2 の資産 2 の

市場価格が下落していないことも、それを示唆しているのではないかと思われる。なお、資産2の市場価格が8700前後に収束する点に関する詳細な検証は今後の課題とする。

4 まとめと今後の課題

本研究では、分散投資規制が資産価格急落時の市場に与える影響を人工市場を用いて検証した。具体的には、資産1と資産2のファンダメンタル価格が一定の場合と、資産1のファンダメンタル価格のみ途中で急落する場合で実験を行った。その結果、資産1と資産2のファンダメンタル価格が一定の場合は分散投資規制が導入された場合と導入されない場合の価格推移の違いは見られなかった。また、資産1のファンダメンタル価格が急落する場合は、分散投資規制が導入されているときの資産1の市場価格は規制なしの価格推移と比較して、資産1の市場価格が急落後のファンダメンタル価格に到達した後、価格がオーバーシュートすることが確認できた。また、資産2の市場価格も分散投資規制が導入された場合、資産1の市場価格が下落するのに連動して価格が下落することが確認できた。

今後の課題としては、以下の通りである。現状のモデルでは分散投資規制に違反したエージェントの買い注文が板上に残ったままになっており、それが資産1の価格がオーバーシュートする一因であると考えられる。そのため、分散投資規制に違反したエージェントの買い注文が板上に残らないようにすること、そして、分散投資規制の対象とならないエージェントも参加させ、それらの注文も板上に残るようにすることが考えられる。また、エージェントの初期キャッシュ量やリスク資産の初期保有数の値を変更することで、規制が市場に与える影響の違いがみられるか確認することが挙げられる。

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。

謝辞

本研究は公益財団法人全国銀行学術研究振興財団とJSPS 科研費 15K01211 の助成を受けたものです。この場を借りてお礼申し上げます。

参考文献

- [1] 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.
- [2] 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.
- [3] M. Cremers and A. Petajisto, "How active is your fund manager? A new measure that predicts performance," *Review of Financial Studies*, Vol.22, No.9, pp.3329-3365, 2009.
- [4] C. Chiarella, G. Iori, and J. Perello': The impact of heterogeneous trading rules on the limit order book and order flows, *Journal of Economic Dynamics and Control*, Vol. 33, No. 3, pp.525-537, 2009.
- [5] S.-H. Chen, C.-L. Chang, and Y.-R. Du: Agent-based economic models and econometrics, *Knowledge Engineering Review*, Vol. 27, No. 2, pp. 187-219, 2012.
- [6] T. Mizuta, K. Izumi, I. Yagi, and S.Yoshimura: Regulations' Effectiveness for Market Turbulence by Large Erroneous Orders using Multi Agent Simulation, In *Proceedings of IEEE Computational Intelligence for Financial Engineering and Economics 2014(CIFER2014)*, pp.138-143, 2014.
- [7] 野崎 淳, 水田 孝信, 八木 勲: 人工市場を用いた分散投資規制が市場に与える影響分析, 第15回金融情報学研究会, 1J4-OS-13a-4, 2015.
- [8] 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*, Vol.133, No.9, pp.1694-1700, 2013.
- [9] R. Cont: Empirical properties of asset returns: stylized facts and statistical issues, *Quantitative Finance*, Vol.1, pp.223-236 (2001)

バックテストに代わるクオンツ戦略の新しい検証方法

A New verification method of quant strategies alternative to back testing

野村 至紀

Yoshinori Nomura

シンプレクス・アセット・マネジメント株式会社
Simplex Asset Management Co., Ltd.

Keywords: Back Test, Quant Strategy, Time Series Analysis, Prediction of Stock Price, Forward Test, Millennium Test, Artificial Intelligence, Artificial Market, Market Simulation

Abstract: This article introduces a new verification method of quant model strategies as an alternative to back testing. New quant strategies will always suffer from a “chicken and egg” problem, finding initial investors who are afraid of the phenomenon that the new strategy, with good looking back test results, will sometimes fail in real investment; “betrayal of the back test”. This article proposes a concept of “forward test” and “millennium test” as new tools to avoid the “betrayal of the back test” and to evaluate the forecasting capability of the new quant model. It also discusses a real application of the forward test and millennium test under the new quant strategy, displaying the strategy’s capability to forecast and generate positive returns over time.

はじめに

人工能をはじめとする計算機技術の進化及びデータの可用性の拡大により、近年は世界で様々な新しい投資戦略が提案されており今後更にその数は増加する。そうした投資戦略の中には例えば人工能に関する技術を用いることで独自の収益機会を追求するなど、既存の投資戦略との差別化を図る試みがなされている。こうした新しい投資戦略を用いた投資商品を組成しようとする際に最初に起きる問題は運用資金集めである。

通常、こうした新しい投資戦略の顧客はプロの機関投資家である。だが他人の資金を運用する責任を付託された機関投資家は「新しい投資戦略」というだけではその新しい投資商品に投資することは出来ない。機関投資家としての責任を全うするために十分に信頼に値する投資戦略であることを入念に調査した上で投資の意思決定を行う。この際、重視される項目の一つがトラックレコードと呼ばれる過去の運用成果（パフォーマンス）の実績である。

しかし、新しい投資戦略の場合には当然ながら実績が存在しない。このため、過去数年間にわたり遡って仮に一定の投資方針で運用を行なったと仮定した場合のシミュレーションを行うことがある。このシミュレーションを通常バックテストと呼ぶ。バックテストには実際の運用成果ではないことに伴うい

くつかの問題が含まれている場合があるがその最も深刻な問題の一つは「バックテストの結果は良好だったが、実際の運用を行なったら良好ではなかった」という現象である。そしてこれは特殊で稀な現象というよりは、比較的多くの機関投資家が過去に経験もしくは聞いたことがある現象である。この問題を本稿では「バックテストの裏切り」と呼ぶ。

実務的には機関投資家は「バックテストの裏切り」を恐れて誰か他の投資家が投資して期待通りの投資成果が得られることを確認した上でなければその新しい投資戦略に投資出来ないと考える傾向がある。これは典型的な「鶏と卵」の問題であり、結果的に新しく魅力的な投資戦略が提案されても最初の投資家がいなかったために実績としてのトラックレコードを積上げることが出来ず、新しい投資戦略は日の目を見ることが出来ず、ひいては顧客たる投資家は新しい収益機会を享受することが出来なくなってしまう。

本稿では、「バックテストの裏切り」を解決すると考えられる手法を提案し、実行可能な投資戦略の数理モデルの事例を用いて評価を行なった。

バックテストの裏切りの原因仮説

「バックテストの裏切り」には2種類ある。①モデルには予測力が無く実際にもワークしない場合と②モデルには予測力があつたが実際にはワークしなくなる場合である。前者は分析アプローチに問題が

あるため分析結果が意図と異なるか、分析アプローチは良くても分析結果の解釈に問題がある場合である。後者は分析や解釈に問題が無くても分析結果の前提が変わってしまったため実際には分析結果が有効ではなくなる場合である。

仮説① 過去の説明力 ≠ 将来の予測力

用いたモデルが過去の市場の現象をうまく説明出来たととして、それは将来の市場の価格形成を効果的に予測することが出来るだろうか。

少なくとも「あるモデルが将来を効果的に予測できるためには過去に起きた事象をうまく説明できないといけない」が、逆は一般には成立しない。

例えば、250日移動平均線が相場の上昇や下落のタイミングを上手く説明しているチャート分析があったとする。しかし、それをもって250日移動平均線が長期安定的に将来を効果的に予測できるはずだとは言えない。

またマルチファクター・モデルという株式や債券などのリターンの形成要因を、複数の要因（ファクター）に分解して表す統計モデルがある。複数のファクターを用いることでリターンやリスクを分解することができ、各々のファクターがリターンにどの程度影響を与えたか、リターン要因分析を行うことができる。最も基本的なのはファーマー・フレンチの3ファクター・モデル [1]であらう。

$$r_{i,t} = \alpha_i + \beta_{M,i}r_{M,t} + \beta_{SMB,i}SMB_t + \beta_{HML,i}HML_t$$

ここで $r_{i,t}$ はi番目の株式の時刻tにおける期待超過収益率、 $r_{M,t}$ は株式市場のリスクファクター、 SMB_t は小型株ポートフォリオのリターンから大型株ポートフォリオのリターンを引いた時価総額に対するリスクファクター、 HML_t は簿価/株価比率の高いポートフォリオから低いポートフォリオのリターンを引いたバリュエーションに対するリスクファクターであり、それらのファクターの係数 β はそれぞれのファクターに対する各株式固有の感応度である。ファーマとフレンチは、このような定式化がCAPMのフレームワークで予想される収益率を継続的に上回るパフォーマンスとなることを示した [2]。マルチファクター・モデルはこの3ファクター・モデルをより多くのファクターに拡大したモデルである。

この分析方法は一つの時間断面を固定した分析（クロスセクション）であり物理的因果関係を表してはいない。左辺のリターン要因を右辺に分類しているが、右辺の要素が原因でその結果ひき起こされた現象が左辺のリターンではない。ある時点で起きた事象の原因は、その時点より前の時点で発生した事象でなければならない（因果律）。これは学術的には当たり前なので議論の対象にはならないが、

実務的には混同されうる危険がある。

実務におけるモデル作成においては、最初から良い結果になることは無いため多くの試行錯誤を繰り返す。例えば「この年の1月のファクターリターンが上手くいかないから、なんとかそれを回避する方法は無いか」、「気づいたらこの期間はずっとこういう銘柄がアウトパフォームしているから、それを選択できる自然なファクターは無いか」という答え合わせ的な発想になる。その様にして作成したロジックは、バックテストの期間で有効なファクターが選択されていることが分かっているので当該期間に最適化してリターンが良く見えることは間違いない。そのファクター選択にたまたま将来にわたる普遍性も備わっていれば良いが、一般にその保証は無い。

この混同がなされた結果、独自に構築したモデルが「一定のファクターの組合せ方を採用する場合に高い超過収益率を実現できた」という統計事実が発見された時に、「一定のファクターの組合せ方」が上手だから「高い超過収益率を実現できた」という読み替えを暗黙に行ってしまう危険がある。正しくは「高い超過収益率の要因を分解すると、その一定期間では●●のファクターが効いていた」と言っているに過ぎない。その場合には、当該一定期間を過ぎてしまうと有効だと思った手法が有効ではなくなり「バックテストの裏切り」が起きる可能性がある。

仮説② 過学習

過学習は学習用データに含まれるが本来学習させたくない情報までモデルが学習してしまう結果、モデルに説明力があるように見えるが実は意味が無く、予測力等の期待した成果が得られない問題をいう。

過学習が起きる原因は①モデルの媒介変数同士に相関がある場合（多重共線性）、②モデルの自由度が大きすぎる場合（オーバーフィッティング）、③モデルの媒介変数と誤差項に強い相関がある場合（内生性）、④モデルの入力変数に内在するランダムネスが強すぎる場合（「ランダムウォーカーの罠」と呼ぶ）等がある。

多重共線性は、似たような統計的意味を持った説明変数（相関の高いファクター群など）を複数用いると説明精度を説明変数同士が食い合いおかしな結果を生む現象であり非線形なモデルでも同様な問題は起きる。

オーバーフィッティングに関する典型例は、時系列を多項式で外挿した際に、多項式の次数を上げるとより当てはまりが良くなる現象である。説明力はあるように見えても、大抵の場合予測力は無い。

内生性 [3]は計量経済学の用語である。例えば3ファクター・モデルでは企業の決算発表タイミング

の情報がモデルに陽に含まれておらず誤差として扱われているが、決算発表日が集中して相場が大きく動いた場合に、リターンと誤差項に強い相関が生じる [4]¹。この際、重回帰分析を行うと3つのファクターにリターンを説明させようとするが当該3ファクターには決算日効果は無いため、決算日発表のあった企業の外れ値がモデル全体で強い影響力を發揮してしまい、結果の推定値は仮に良く説明しているように見えてもあまり意味が無い結果となる。

ランダムウォーカーの罫は本稿だけの用語だが、説明変数に強いランダムネスが含まれている場合に説明変数の本来の意味ではなくランダムネスが被説明変数を説明してしまう現象である。「それは統計的検定をするから大丈夫」と安易に考えると危険なことがあることを簡単な数値実験の例で示す。

独立にランダムウォークする変数 $x_n(t)$ が10個あるとしよう。


$$x_n(t+1) = x_n(t) + \varepsilon_n(t) \quad (n = 1, \dots, 10, \quad x_n(0) = 0) \quad (1)$$

ここで $\varepsilon_n(t)$ がランダムウォークを生み出す乱数項で±1.0の範囲の実数をとる。この10個を説明変数として、時間に正比例する時系列 $X(t)$ を被説明変数として重回帰分析を行う。

$$X(t) = t, \quad (t = 0, \dots, 200) \quad (2)$$

この結果(図表1)のとおり、 $X(t)$ をランダムウォーク $x_n(t)$ の重み付き合算で近似する。結果はランダムウォークの重み付き合算が良く直線を近似している様に見えてしまう。重決定係数は0.98、 t 値の絶対値の多くは2を超えP値も最大で26.6%で多くが1%を下回る。

図表 1:ランダムウォークによる重回帰結果



当然ながらランダムウォークの重み付き合算は、 $200 < t$ でこのまま $X(t)$ と伴に直線的に上昇するはずが無くランダムウォークとなる。すなわち「バックテストの裏切り」が起きる。例えば、ランダムに歩くゾンビを10体鎖でつないで歩かせたら力が釣合ってまっすぐ歩いているように見えても安心してはいけない。いきなり方向転換してあなたを襲うかも

知れない。

このようにランダムネスが強い変数を説明変数に用いる場合には注意を要する。特に金融・経済統計に用いられる説明変数の多くは非常に強いランダムネスを含んだデータが多く、分析者が良いリターンとなる結果を求めて「ファクターを増やして説明力が向上したら意味があるのではないかと考えてしまう危険がある。

過学習問題に対する単純で効果的な処方箋としてモデルで用いる媒介変数(乱数の源)の数を出来る限り減らして意味のある関係だけを残す方法がある。数物理学の分野では変数を減らすアプローチが多いがモデルがシンプル過ぎて現実の説明力が低い課題がある。一方、人工知能の分野では変数を減らさずに別の方法が取られるが説明力があっても変数の関係が理解出来ないほど複雑化する傾向がある。

仮説③ 市場環境の変化に適応出来ない

市場環境は常に変化し続けるためバックテストの対象期間を10年超など長期間で行うことで様々な市場環境の変化をモデルに織り込ませるのが普通である。しかし、市場の動きは確率的には100年に一度と言われるような事象でも起きることがあり、そうした事象が起きた場合にはその後長期にわたってこれまでとは異なる環境が継続することがある。

このようにバックテストが前提としていた市場環境と大きく異なる環境が継続する場合にはモデルがワークしない可能性がある。

通常のコオントラクト戦略の場合には、このような事象が起きて運用しているファンドの基準価額が芳しくない状況が継続していることが確認された場合には(例えば、数ヶ月のモニタリング期間を経ても改善が見られない場合には)モデルの改良が試みられる。アナリストが改めて膨大な時間を投入してバックテストを繰り返しそうしたテストの中から最も良いと考えられるモデルを選択する。通常、このプロセスにも数ヶ月を要する。新しいモデルへの変更についての社内承認を経て、場合によってはその変更方針を顧客である機関投資家に事前説明を行い了承されたから新モデルを導入することとなる。

この結果、旧モデルがワークしなくなってから新モデルが導入されるまで数ヶ月を要する。この間にパフォーマンスがおおいに毀損してしまっているか、場合によってはまた別の市場環境に変わってしまっている可能性もある。結果的に新モデルを導入しても期待通りの結果が出ない可能性がある。

この問題への処方箋としては、優秀な人間のファ

¹ リターンの外れ値と誤差の外れ値が相関係数を極端に押し上げる。

ンドマネージャーが行なっているように市場環境の変化に対して迅速に適応して「バックテストの裏切り」を回避することが重要であると考えられる。

フォワードテストの提案

ここでは「バックテストの裏切り」が起きにくくすることで新しい投資戦略に実トラックレコードがなくても一定の評価が可能となるフォワードテストという方法を紹介する。考え方自体は Pardo²によって最初に議論されたが [5], コンピュータが自動的に過去を学習して将来を予測する仕組みが実現している場合に力を発揮するため実行するハードルが高く現在でもあまりメジャーな地位を得ていない。また Pardo は Walk Forward Optimization と呼んでいるが本稿では単にフォワードテストと言う。

フォワードテストの考え方

フォワードテストとは、過去の市場の情報をコンピュータが読み込んでなんらかの方法でプログラムの内部変数を直近の市場環境に適応（学習）させた上で、コンピュータが将来予測を行い具体的なトレードを指示し、その指示によってトレードが執行されることで日々の損益が確定する仕組みである。この損益を累積して得られた長期的なパフォーマンスは、純粋にモデルの予測力のみによって実現しているため直接モデルの予測力を評価できる（図表 2）。


マルチファクター・モデルのようなモデルを構築する際にあるファクターが一定期間継続的にアウトパフォームしていたことを知った上で、その期間にそのファクターをオーバーウェイトするような手続を含めることはフォワードテストではできない。

フォワードテストは「バックテストの裏切り」の原因仮説を排除することができる。仮説①については、全てのモデルの内部変数は予測時点より過去の情報によって決定されるため、過去の説明力を将来の予測力と混同することが無い。仮説②については、過学習にはまっていればフォワードテストの結果は長期安定的に予測力が発揮できないことで確認される。仮説③については、市場環境の変化に対しても人間のファンドマネージャーのように随時適応し続けるため、モデルの市場環境の変化への適応能力を検証できる。

こうしてみると、予測力のみで日々の損益が確定しているという点においては、取引コストやマーケットインパクトを無視すれば現実のトラックレコー

ドと論理的に区別することは出来ない。

図表 2:フォワードテストの概念図



また、フォワードテストに耐えうる高度なモデルの場合には、中身がブラックボックスになって投資戦略の詳細を理解し難い場合もあるが、仮に詳細まで理解出来なくともフォワードテストによりモデルの予測力を直接評価することが出来る。

それでも「フォワードテストの結果が良かったモデルだけを持ってきただけで後付けだから、モデルが将来ワークするか分からない」という指摘は正しい。論理的にはこれは「良好な実トラックレコードのあるファンドマネージャーを見つけてきただけで後付けだから、そのファンドマネージャーが将来ワークするか分からない」という主張とあまり区別がない。これは多少変わったチューリングテスト³として考えてみると哲学的には面白いかも知れないが、むしろ機械は計算間違いをしない分人間より優れているとも言える。

フォワードテストの結果が信用出来ない場合として現実には考えられるのはフォワードテストが正しく実行されない場合である。例えばモデルのパラメータに予想時点より将来の情報を分析者が知った上で手を加えた場合は当然不適当な結果となる。こうした問題が懸念される場合には、異なる市場環境でもモデルが想定どおりにワークするかをテストする必要がある。その考え方を次に示す。

ミレニアムテスト

人間のアクティブマネージャーでも 10 年のトラックレコードがあれば十分に 20~30 年となれば相

² Pardo はフォワードテストを売買シグナルモデルの頑強性を確認する程度のツールと考えておりモデルの予測力を評価するという発想とは多少異なるようだ。Pardo は自身で開発した Walk Forward Optimization のソフトを販売しており投資家がソフトに組み込まれた様々な投資戦略で自身のモデルを試行錯誤出来るようにした。Pardo は自身のツールを使っても十分な予測力があるモデルはそう簡単には出来ないことを経験

していたため予測力ではなく頑強性の評価ツールと位置づけたのかも知れない。
³ チューリングテスト：ある機械が人間と区別できないほど知的かを判定するテスト。機械はミスしないが人間はミスするため、機械はチューリングテストに不合格になるという主張もある。

当なベテランという評価だろう。それでも高々数十年の経験ではあらゆる金融環境を経験したとは言えない。東京証券取引所の前身であった東京株式取引所は 1878 年 6 月 1 日が初立会い⁴であり 1 世紀程度の歴史があるが逆に言えば高々 1 世紀のオーダーしかない。コンピュータであればそうした時間の制約条件は相当程度取り払うことが出来る。

乱数等を用いて人工的に仮想的な市場環境を作り出して 10 年を 1 セットで 100 回、即ち 1,000 年分のフォワードテスト（ミレニアムテスト）を行うことも可能である。もちろん、人工的な市場のみならず実際の外国の同アセットクラスの過去の市場データ等をテスト対象に含めることも可能だ。

ミレニアムテストを用いれば、仮にモデルが特定の市場の将来の情報を知った上で構成されたものであれば想定と異なるテスト結果となる。

またミレニアムテストにより、モデルの不得意な環境はどういう環境なのか、特に最悪な環境でもどの程度の損失が起きるのかを事前に知ることが出来る可能性がある。ここで現実の外国等の過去の市場データでテストすると何の要因が損失原因かを特定することが難しいが、条件がコントロールされた人工的な市場環境であれば損失原因を特定することは比較的容易であり、モデルの進化を促進することが期待出来る⁵。

ミレニアムテストのための市場模型

ミレニアムテストを行うためには仮想市場の模型を作る必要がある。金融市場に良く似た時系列を生成するモデルの先行研究としてはマンデルブローによるフラクタル幾何学を用いた市場模型がある [6]。これ以外にも様々な模型が考えられ、市場の理解が深まるにつれてより現実的なモデルが提案されていくと考えられる。

事例研究

実際の数理モデルを用いてフォワードテストを行なってみた。ここで用いるモデルは単純に過去の TOPIX（東証株価指数）の価格の時系列だけを読み込んで、直近の市場環境に適応（学習）したのち将来の TOPIX の価格を予想してトレード指示を出し、TOPIX 先物でトレードをするモデルである。

市場価格の将来を予測する数理モデル

用いた数理モデルは物理学の領域で用いられる考

え方を活用しているがここでは理論の詳細には立ち入らず考え方を紹介する。フォワードテストでは数理モデルの詳細が分からなくても予測能力を評価出来る。

市場で取引されることによって価格形成される金融商品の多くは共通の普遍的現象がある。一方に価格が動き続けるトレンドの発生と、短期的に価格が動き過ぎたら少し前の価格水準に戻る平均回帰現象である。数理モデル構築の第 1 ステップとして、こうした現象の時間発展を記述する数理モデルを構築した。こうした数理モデルの先行研究としては PUCK model [7] などがあるが本稿では PUCK model とは異なる数理モデルを用いた。

第 2 ステップで上述の数理モデルが現実の市場の過去の時系列を学習して直近の市場環境に適応するためのプロセスをシミュレーテッド・アニーリング [8] と強化学習の考え方を用いて構成した。実装は C++ でコーディングした。

当モデルの特長は、インプット情報の単純さにある。過去の価格の時系列のみがインプット情報であるため乱数の源が原理的に一つしか無い「ランダムウォーカーの罫」の懸念が殆ど無い。

フォワードテストの事例

投資戦略としては、TOPIX 先物のエクスポージャーを純資産総額のマイナス 50% からプラス 50% の範囲（合計で 100% の幅）で変動することで株式相場の上昇と下落のどちらでも収益機会とする自由度を与えた。トレーディングは日々の株式市場の寄りきと大引けの 2 回取引を行うことが出来る。運用に係る報酬や取引コスト⁶は考慮せず市場価格で売買が成立するものとした。

上記戦略を 2002 年末から 2016 年月末までの約 14 年間フォワードテストした結果を図表 3 に示す。

図表 3: フォワードテストのパフォーマンス

	数理モデル	TOPIX
Total Return	323%	70%
IRR	11.7%	4.1%
Sharpe Ratio	0.97	0.23

この期間のトータルリターンは 323% であり、年率幾何平均リターン (IRR) にすると 11.7% となる。IRR を月次のリターンから算定したリターンの年率標準偏差で割った比率 (Sharpe Ratio⁷) で見ると 0.97 と

⁴ 日本取引所グループのホームページより (<http://www.jpx.co.jp/>)

⁵ 現代の AI 将棋が人間の対戦手を介さずに機械同士の対戦で進化し続けている様に、数理モデルが仮想市場模型を相手にして現実の市場データが無くても進化していく可能性も将来的にはあるかも知れない。


⁶ 株価指数先物の取引は現物株式に比べて売買手数料が低い傾向がある。

⁷ 実務における Sharpe Ratio の値の解釈例を次に示すが、評価は相対的なものなので必ずしもこの通りではない。"a ratio of 1 or better is considered good, 2 and better is very good, and 3 and better is considered excellent"

(http://www.investopedia.com/articles/07/sharpe_ratio.asp#ixzz40xU529Cc)

なる。TOPIX との対比で見ると TOPIX のパフォーマンスを長期的にアウトパフォームすることが確認された。これをチャートにして相対比較したのが図表 4 である。

図表 4: フォワードテストの相対パフォーマンス (2002 年 12 月末を 100 に基準化)



バックテストとの対照比較

上記の数値モデルを用いて 2002 年 12 月末から 2008 年 4 月末までの 5 年間 4 ヶ月⁸をバックテスト期間とし、当期間において内部パラメータは当期間のみに最適化したパラメータ群を選択し当期間にわたって固定して計算した。当期間の後にはバックテストで決定した内部パラメータを引続き固定してシミュレーションを行うことで「バックテストの裏切り」効果を検証した。

この結果、バックテスト対象期間は図表 5 のとおり IRR が 13.7% で Sharpe Ratio が 1.34 であった。

図表 5: バックテスト期間中のパフォーマンス

	数理モデル	TOPIX
Total Return	99%	61%
IRR	13.7%	9.4%
Sharpe Ratio	1.34	0.62

次にバックテスト期間後 (2008 年 4 月末から 2016 年 1 月末) において、バックテストで決定した内部パラメータを固定したままパフォーマンスを測定した (図表 6)。この結果、IRR は 5.6% で Sharpe Ratio は 0.48 とバックテストより悪化し「バックテストの裏切り」効果が確認された。一方で内


部パラメータを一切変更しなくとも年率 5.6% のリターンが得られる点は数理モデルに内在する予測力がバックテスト期間後も存在しているためと考えられる。

図表 6: バックテスト期間後のパフォーマンス

	数理モデル	TOPIX
Total Return	52%	5%
IRR	5.6%	0.7%
Sharpe Ratio	0.48	0.03

以上の結果を相対パフォーマンスグラフで示したのが図表 7 である。バックテストは対象期間に最適化しているため相対的に良いパフォーマンスであり、数理モデルのフォワードテストより良い。しかしバックテスト期間後のリターンはプラスではあるもののフォワードテストをアンダーパフォームし、市場環境変化に適応するプロセスの効果が確認された。

図表 7: バックテスト期間前後の比較



ミレニアムテストの事例

マンデルブローが考案したフラクタル幾何学を用いた市場模型の考え方を参考に上述の数値モデルをミレニアムテストした。マンデルブローは「市場価格のパターンから価格の予測をして、お金をつぎ込むということは、怖さを知らないからこそできることもと言える」、「価格の予想は無理と思え」と記述している [6] が、結果はそこまで悲観的ではない可能性が示された。

ミレニアムテストで用いた市場模型の構成方法は次のとおりである。まずマンデルブローのように時

⁸ 期間が中途半端なのは用いた数理モデルの統計処理の特性上の都合


間の始点と終点を先に決めてから特定の騰落パターンを自己相似的に埋め込む幾何学的構成方法 [6]は用いない。これは時間の始点と終点を先に決定する方法は時間発展する市場の模型として不自然であるためである。これに変わって市場模型に求める要件として、TOPIX のリターンの時系列の統計的性質をある程度再現することと、リターン系列の構造にフラクタル幾何的な性質を内在することを採用した。

TOPIX のリターンの時系列の統計的性質としては月次リターンから算定した年率換算ボラティリティが 20%程度であることを目安とした。

またリターンの時系列にフラクタル構造を与えるために三角型の要素関数を用い、この要素関数に相似形の三角形を重ね合わせる方法を用いた。この際、乱数を用いることでよりランダム性の高い市場模型を作成した（詳細は Appendix 参照）。

このようにして構成した市場模型の価格の時系列の事例を図表 8 に示す。


図表 8:市場模型の例 (2000/1/1=100 で基準化)




この模型を 100 種類乱数で生成して 10 年ずつフォワードテストした結果を図表 9,10 に示す。10 年分の時系列の 100 セットの平均標準偏差は 23.0% であり、そのばらつきの標準偏差は 1.3% であった。

ミレニアムテストの結果、数理モデルの IRR は 29.9% でその標準偏差は 2.7%、Sharpe Ratio は 4.78 でその標準偏差は 0.48 である。この結果かなりのランダムネスを含んでいてもフラクタル的パターンのリターン構造を持った時系列は予想が可能であることが示された。現実の市場は今回の模型よりも複雑で予測は難しいが、簡単な問題を確実に解ける事実も重要な確認である。

図表 9: 数理モデルのミレニアムテスト結果



図表 10: 市場模型の基礎統計量 (参考)



おわりに

これまでアクティブマネージャーが育成されてきた背景には、投資銀行の自己勘定取引部門による貢献が大きかった。しかし、リーマンショック後の世界的な金融制度基盤整備の流れによりボルカールール⁹等の規制が強化されてきた結果、多くの投資銀行のプロップデスクは閉鎖もしくは大幅縮小を迫られて来た。結果的に新しい投資マネージャーが育つ機会が失われつつある。

一方で世界の緩和的金融環境を背景に膨張したマネーは投資先を求めており結果的にヘッジファンドへの預かり資産残高は増加し続けており、優秀なマネージャーが少ないことが問題となっている。

こうした環境において人工知能等の新しい技術を用いた運用戦略が今後更に高度化されて適切に評価され受け入れられることで、将来的にはマネージャー不足の問題も解消できる可能性もあるのではないかと考えている。

Appendix 市場模型の構成方法

フラクタル的なリターン構造を与えるために図表 11 のような要素関数 $F(t, k)$ を導入した。 $F(t, k)$ は周期 $3k$ を持つ三角形をつなげた関数である。


ここで $\text{round}()$ 関数は入力値の小数点以下を四捨五入して整数のみ返す関数であり、 n は自然数である。 n の除数 $1.75 (=7/4)$ は n を変えた際の周期性 k がより複雑になるようにするための値である。

$n=1 \sim 6$ まで変えた場合の $F(t, k)$ の時系列を図表 12 に示す。図表 12 では要素関数の相似図形によって時系列が構成されていることが分かる。こうした


⁹自己勘定で利益を得るための取引を行うことへの規制を含む

時系列を一定の方法で合成することでフラクタル的な構造を与えた市場模型を作る。

図表 11: フラクタルな時系列の要素関数 F




図表 12: 時系列のフラクタル構造例




次に 1 周期ごとに振幅が乱数によって変化する関数 Random(t)を図表 13 のように定義する。

図表 13: Random 関数



F(t,k)と Random(t)を乗じることで図表 14 のように振幅がランダムに変化する構造を与えた。

図表 14: 要素関数と Random 関数の積の時系列



また、F(t,k)は周期と振幅が比例する構造があるためこのまま n を変えて合算すると大きな n の効果が時系列を支配するため予測が簡単になる。よって n に対する振幅の補正 A(n)を(2)式で定義する。F(t,k)の最大振幅は 2k なので補正は 1/k のオーダーに近いことが妥当と考えられる。

$$A(n) = \frac{0.04}{\left(\frac{n}{31.75}\right)^{\exp(1-0.4n)}} \quad (2)$$

A(n)は $n \leq 4$ では単調減少で n が小さいほど振幅を大きく評価し、 $n=4$ で最小値 $A(4)=0.01842$ を取り $4 < n$ では単調増加関数で $A(n)=0.04 (n \rightarrow \infty)$ となる。この関数形により n の大きな場合に振幅が減少しす

ぎない構造を与えた。

$$R(t) = \sum_{n=1}^N A(n)F(t, k) \text{ Random}(t, n) + \epsilon(t) \quad (3)$$

$$\text{Vol}(\epsilon'(t)) = 2\text{Vol}\left(\sum_{n=1}^N A(n)F(t, k) \text{ Random}(t, n)\right) \quad (4)$$

ここで $\epsilon'(t)$ はそのボラティリティ $\text{Vol}(\epsilon(t))$ が $\sum_{n=1}^N A(n)F(t, k) \text{ Random}(t, n)$ のボラティリティの 2 倍になるように選んだ乱数で長期平均は 0 である。1 タイムステップの%リターンは $R(t)/100$ で与えられる。この結果、市場模型の価格 P(t)の時間発展は以下によって記述される。但し 2 タイムステップで 1 日とカウントした。

$$P(t+1) = P(t) \left(1 + \frac{R(t)}{100}\right) \quad (5)$$

謝辞

本論文の作成に当っては千葉商科大学の西山昇客員教授に多大なる助言を頂いたことに感謝致します。

参考文献：

- [1] Fama, E.F. and K.R. French, Size and book-to-market factors in earnings and returns, Journal of Finance 50, 1995
- [2] 祝迫得夫, ノーベル経済学賞 2013 年解題 ファーマ, ハンセン, シラー教授の資産価格の実証分析への貢献, 一橋大学経済研究所, Discussion Paper Series A, 2014 No.599
- [3] Wooldridge, Jeffrey M., Introductory Econometrics: A Modern Approach (Fifth international ed.), Australia: South-Western, 2013
- [4] Stroyny, Alvin L., "Estimating a Combined Linear Factor Model" In Linear Factor Models in Finance, Elsevier, 2005
- [5] Robert Pardo, The Evaluation and Optimization of Trading Strategies, Wiley, 2008
- [6] Benoit B. Mandelbrot, Richard L. Hudson.:禁断の市場フラクタルで見るリスクとリターン, 東洋経済新報社, 2008
- [7] Misako Takayasu, Kota Watanabe, Takayuki Mizuno and Hideki Takayasu, Theoretical Base of the PUCK-Model with Application to Foreign Exchange Markets, Proceedings of Econophysics Approaches to Large-Scale Business Data and Financial Crisis, Springer, 2010
- [8] Kirkpatrick, S.; Gelatt Jr, C. D.; Vecchi, M. P., "Optimization by Simulated Annealing". Science 220 (4598): 671-680., 1983

ディスクレーマー：

本稿は筆者個人の考えに基づくものであり、筆者が現在所属して

いるシンプレクス・アセット・マネジメント株式会社の公式見解
ではありません。

イジングモデルによる複数時系列の株価変動シミュレーション

Multiple time series simulations of stock price dynamics by Ising model

高石哲弥

Tetsuya Takaishi

広島経済大学

Hiroshima University of Economics

Abstract:

これまでの実証分析によって株価の変動は単純なランダムウォークではなく、いくつかの特徴があることが知られている。例えば、(1) 収益率の自己相関は小さいが、絶対値収益率の自己相関は長期にわたっている、(2) 収益率分布は正規分布とは違い、裾野の広がった分布をしている、(3) ボラティリティクラスタリングが現れる、等の特徴がある。これらの特徴を捉えた、非常に簡単なモデルとして Bornholdt のイジングモデルがある。本研究では、このモデルを相互作用のある複数の株価時系列モデルに拡張し、シミュレーションを行った。その結果、元のモデル同様の株価の変動の性質を持ちつつ、且つ株価のボラティリティ間に相関のあるモデルとなることが分かった。

1. はじめに

株価の変動は性質は実証分析によってよく調べられており、それらの性質は Stylized facts[1]として知られている。例えば、(1) 収益率の自己相関は小さい、(2) 絶対値収益率の自己相関は長期にわたる、(3) 収益率分布は正規分布とは違い、裾野の厚い分布である、(4) ボラティリティクラスタリングという変動の大きい時期が続いたり、変動の小さい時期が続く、などの性質がある。株価変動のシミュレーションを行う場合、実証的に知られているこれらの性質を再現できるモデルを使うのが望ましい。本研究では、シミュレーションに Bornholdt のイジングモデル[2]を利用するが、このモデルは非常にシンプルでありながら、これらの性質を反映することができる。このモデルでは2つの相反する作用のみを導入する。1つは周りに同調するマジョリティ効果に対応し、例えば周りに買う人が多ければ自分も買おうとし、逆に売る人が多ければ自分も売ろうとすることに対応する。もう1つは、全体の動きと反対の行動をとるマイノリティ効果である。これは、市場全体に買う人が多ければ自分は売ろうとし、売る人が多ければ買おうとすることに対応する。これら2つの作用によって、このモデルは複雑な非定常な動

きを見せる。Bornholdt によるこのモデルの提唱後、このモデルを使った研究がなされているが、それらは株価の1時系列を扱ったものである。実際の市場では多数の株価が取り引きされ、それらの株価間には相関がある場合が多い。従って、現実的な市場のシミュレーションには、多数の株価の変動をシミュレーションできるモデルが必要となる。本研究では、Bornholdt のモデルを拡張し、複数の株価のシミュレーションを行うモデルを構築し、そのモデルによるシミュレーションの結果を報告する。

2. Bornholdt モデル

D 次元の L^D 格子を考える。エージェント i はこの格子点 i にいるとする。この時、全体で $N = L^D$ 個のエージェントが存在することになる。エージェントはスピン S_i を持ち、 S_i は $+1$ または -1 の値をとるとする。ここでは、 $+1$ の場合をエージェントの買う状態、 -1 の場合を売る状態と考える。エージェントは周りのエージェントの状態によって確率的に自分の状態を決める。まず、マジョリティ効果に対応する部分は通常のイジングモデルと同じで、最

近接エージェントの取る状態によって決まる。イジングモデルと違うのはマイノリティ効果に対応する部分である。市場全体の状態を測る量として磁化を導入する。磁化はスピン S_i をすべて足し合わせたものとして定義される。磁化が正の値であれば、買う状態が多く、逆に負の値であれば売る状態が多いことになる。また、磁化の絶対値が大きいときは、市場が過熱してバブル的になっていると考えられる。このようなバブル的な状態はいずれ弾けると考えると、将来のロスを守るためには過熱した状態（マジョリティ）とは逆の状態（マイノリティ）に移っていた方がよいことになる。そこで、マイノリティ効果では、磁化の絶対値が大きいときは、自分の状態を変える確率が高くなるようにする。

以上のことをまとめると、Bornholdt モデルでは以下の確率 p でスピンの状態をアップデートしていく[2]。

$$S_i(t+1) = +1, \quad p = 1/(1 + \exp(-2\beta h_i(t))) \quad (1)$$

$$S_i(t+1) = -1, \quad 1 - p \quad (2)$$

$$h_i(t) = \sum_{j=1}^n J_{ij} S_j(t) - \alpha S_i(t) |M(t)| \quad (3)$$

ここで、 $M(t)$ は磁化を表し、

$$M(t) = \frac{1}{N} \sum_j S_j(t) \text{ で定義される。} J_{ij} \text{ は周りのスピンとの相互作用の強さを表し、普通最近接のスピンのみ } J_{ij} = 1 \text{ とし、その他はゼロとする。} \beta \text{ はオリジナルなイジングモデルでは温度の逆数に対応する。} \beta \text{ の値を相転移温度以下に設定することによって、スピンは揃おうとするが、(3) 式の第 2 項があるために、シミュレーションを行うと、order 相になったり disorder 相に変化したりと複雑な動きを見せる。}$$

図 1 は $L=100$ の 2 次元格子上でパラメータを $\beta=2, \alpha=20$ としてシミュレーションした時の磁化 $M(t)$ の時系列である。アップデートは周期的境界条件のもとで行った。

収益率は[3]に従って

図 1 は $L=100$ の 2 次元格子上でパラメータを $\beta=2, \alpha=20$ としてシミュレーションした時の磁化 $M(t)$ の時系列である。アップデートは周期的境界条件のもとで行った。

収益率は[3]に従って

$$R(t) = (M(t) - M(t-1))/2 \quad (4)$$

で定義する。図 2 は収益率の時系列である。収益率

には変動の大きい時期や小さい時期が続くボラティリティクラスタリングが現れている。




図 1 磁化 $M(t)$ の変動。




図 2 収益率 $R(t) = (M(t) - M(t-1))/2$ の変動。




図 3 収益率分布。




図4 収益率累積分布。

図3はパラメータ α を変えてシミュレーションを行い、その収益率分布を表示したものである。正規分布とは違い、裾野の厚い分布となっている。

図4は収益率の累積分布を表している。裾野に冪的な振る舞いが見られることが分かる。

3. Potts-like モデル

Bornholdt モデルでは、スピンの状態は買うか売るかの2つの状態を取るが、複数の状態を考慮することも可能である。例えば、[4,5]では、買う、売る、何もしないの3つの状態を考えたモデルを提唱している。例えば、買う状態を+1、売る状態を-1、何もしない状態を0とすると、このモデルでは、以下の確率でスピンをアップデートする。

スピンが $S'_i = +1$ または -1 になる確率：

$$P(S_i \rightarrow S'_i) = \frac{\exp(\lambda(h(i, S'_i) - \mu S_i S'_i | M |))}{Z} \quad (5)$$

スピンが $S'_i = 0$ になる確率：

$$P(S_i \rightarrow S'_i) = \frac{\exp(\lambda(h(i, S'_i) - \mu(\varepsilon_i | M | - 2\gamma K))}{Z} \quad (6)$$

ここで、 $h(i, S'_i)$ は周りと同じ状態のスピンがいくつあるかをカウントするものに対応し

$$h(i, S'_i) = \sum_{\langle i, j \rangle} \delta_{S_j, S'_i} \quad (7)$$

で定義される。 $\langle i, j \rangle$ は*i*番目のスピンの周りのスピン*j*についての和を表す。 Z は全確率の和が1になるように規格化するもので、

$$\sum_{k=+1,-1,0} P(S_i \rightarrow k) = 1 \quad (8)$$

を満たすように決定される。 K は以下で定義される inactivity rate で、0になっているスピンの数を全格子数*N*で割ったものである。

$$K = \frac{1}{N} \sum_{i=1}^N \delta_{S_i, 0} \quad (9)$$




図5 Inactivity rate.




図6 収益率分布。

図5は γ の値を変えたときの*K*の値を表す。ここでは、2次元格子、 $L=100$ 、 $\lambda=2$ 、 $\mu=10$ でシミュレーションを行った。

ミュレーションを行っている。 γ 値が小さいときはスピンの0を取る確率が高く、逆に大きいときは0を取る確率が小さくなっている。

図6は収益率分布を表している。 γ 値が大きいときは0をとるスピンの数が少なくなっているのでBornholdtモデルに近づくことになり、図3と同様の収益率分布になっている。一方、 γ 値が小さいときは、指数関数的な収益率分布になっている。冪的ではなく、指数関数的な収益率分布も実際の市場、特に発展途上国の市場で見られることがある[6]。

3. 複数時系列イジングモデル

これまでのシミュレーションでは1時系列のシミュレーションが行われているが、現実の市場はたくさんの株価が取り引きされ、それらの株価は相関を持って変動している。ここでは、複数の株価が相関を持って変動するモデルをBornholdtモデルの拡張によって構築する[7,8]。

今、 K 個の株価があるとする。 l 番目の株価に対して、(3)式を以下のように変更する。

$$h_i^{(l)}(t) = \sum_{j=1}^N J_{ij} S_j^{(l)}(t) - \alpha S_i^{(l)}(t) | M^{(l)}(t) | + \sum_{j=1}^K \gamma_{ji} M^{(j)}(t) \quad (10)$$

ここで、(10)式の右辺3項目が他の株価との相関を磁化 $M(t)$ の値に応じて取り入れる項であり、 γ_{ji} が相関の強さを表すパラメータである。 l 番目のスピン $S_i^{(l)}(t)$ はBornholdtモデルと同様に以下の確率でアップデートしてゆく。

$$S_i^{(l)}(t+1) = +1, \quad p = 1/(1 + \exp(-2\beta h_i^{(l)}(t))) \quad (11)$$

$$S_i^{(l)}(t+1) = -1, \quad 1-p \quad (12)$$

3. シミュレーション

ここでは、3個の株価($K=3$)が相関を持って変動する場合の結果を紹介する。2次元の格子を用い

格子サイズは $L=120$ とし、パラメータは $\beta=2, \alpha=35, J_{ij}=1$ とした。相互作用のパラメータ γ は

$$\gamma = \begin{pmatrix} 0 & 0.05 & 0.1 \\ 0.05 & 0 & 0.15 \\ 0.1 & 0.15 & 0 \end{pmatrix} \quad (13)$$

とし、ここでは対称な相互作用を仮定した。相互作用は $\gamma_{12} < \gamma_{13} < \gamma_{23}$ となっており、これは株1と株2の間の相互作用が一番小さく、株2と株3の相互作用が一番大きくなるように設定されている。

シミュレーションは、逐次ランダムにスピンをアップデートして行き、始めの10,000サンプルはthermalizationとして捨てて、その後の500,000サンプルを解析に利用した。

図7は磁化の変化を表している。ここでは、データの一部(150,001番目のデータから180,000番目のデータ)のみを表示しある。株1と他のデータの間には似た変動はあまり見られないが、株2と株3の間には似た変動が見られる。




図7 複数時系列イジングモデルにおける磁化の変動。

図8は収益率の変動を表している。収益率の定義は(4)と同じである。ここでも、株価2と株価3の間には同時期に似た変動が多くみられる。




図 8 複数時系列イジングモデルにおける収益率の変動。




図 9 複数時系列イジングモデルにおける収益率分布。

図 9 は収益率分布を表しており、Bornholdt モデルと同様に裾野の厚い分布となっている。

表 1 ボラティリティ (株価収益率の絶対値) 間の相関係数。

	Stock1	Stock2	Stock3
Stock1	1	9.91×10^{-2}	0.133
Stock2	9.91×10^{-2}	1	0.212
Stock3	0.133	0.212	2

表 1 は株価のボラティリティ間の相関を求めたものである。ここでは、ボラティリティとして株価収益率の絶対値を利用している。表 1 から、株 1 と 2 の間の相関は小さいが、株 2 と 3 の相関は大きくな

っていることが分かる。これは、(13)のように相互作用のパラメータ γ を設定したことに整合している。




図 10 収益率の自己相関関数。




図 11 絶対値収益率の自己相関関数。

図 10 は収益率の自己相関関数を表しており、自己相関は非常に短期でほぼゼロとなっている。一方、図 11 は絶対値収益率の自己相関関数であるが、長期の相関が見られる。これらの性質は実際の市場の株価収益率で見られる性質と一致している。

4. まとめ

本研究では、1 時系列のモデルである Bornholdt モデルを拡張し、複数の相関のある時系列のモデルに拡張を行い、シミュレーションを行った。株価収益率の性質は元の Bornholdt モデルと同様に、実際の市場の収益率の性質を反映したものとなった。また、絶対値収益率で代用したボラティリティ間に相関が現れるモデルとなった。

参考文献

- [1] R.Cont, Empirical properties of asset returns: stylizedfacts and statistical issues, *Quantitative Finance*, Vol. 1, (2001) pp. 223-236.
- [2] S.Bornholdt, Expectation Bubbles in a Spin Model of Markets: Intermittency from Frustration across Scales, *Int. J. Mod. Phys. C* 12 (2001) pp.667–674.
- [3] T.Kaizoji, S.Bornholdt and Y.Fujiwara, Dynamics of Price and Trading Volume in a Spin Model of Stock Markets with Heterogeneous Agents, *Physica A* 316 (2002) pp.441–452.
- [4] T.Takaishi, Simulations of Financial Markets in a Potts-like Model, *Int. J. Mod. Phys. C* 16 (2005) pp.1311–1317.
- [5] T.Takaishi, Analysis of Spin Financial Market by GARCH Model, *Journal of Physics: Conference Series* 454 (2013) 012041
- [6] K.Matia, M.Pal, H.Salunkay and H.E.Stanley Scale-dependent price fluctuations for the Indian stock market, *Europhys. Lett.* 66 (2004) 909–914.
- [7] T.Takaishi, Multiple Time Series Ising Model for Financial Market Simulations, *Journal of Physics: Conference Series* 574 (2015) 012149.
- [8] T.Takaishi, Some properties of multiple time series Ising model in financial market simulations, 2015 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER), pp.104 – 108, DOI:10.1109/CYBER.2015.7287918

なぜロバストなアルファ（ベータ）推定値が必要なのか — プレミアム VS アノマリーを統計的手法で超えられる？ —

Why We Need Robust Alphas (and Betas)

- Is it possible to beyond “premium vs. anomaly” with the statistical method?

西山 昇

Noboru Nishiyama

Dragons' Desk Ltd. / 千葉商科大学会計大学院

Abstract: OLS (Ordinary Least Square) estimation of sample means and betas can lead to biased estimates of alpha in the presence of certain patterns of heteroscedasticity. There has been discussing on something to do with background of modern portfolio theory for forecasting risk premium and dealing with anomaly. We demonstrate that those patterns occur in practice, and that a robust estimation process eliminates the bias with some algorithms.

Key words: Alpha, Algorithms, Arbitrage Pricing Theory, Backtesting, Linear Factor Models

1. はじめに

最近、資産運用に人工知能を活用していること公表する運用者が増加している。ヘッジファンドなどは、運用の詳細を公開していないため限られた情報から活用方法を推し量るしかない。少なくとも確実なのは良好なパフォーマンスをあげる（アルファをとる）ためのアルゴリズム構築が中心である。[2]

個社ごとに方法は異なるものの、銘柄選択を通じてプラスアルファが獲得できるポートフォリオ構築のための最適化アルゴリズム開発と先物等のデリバティブを組み合わせたトレーディングの売買タイミングを判断するアルゴリズム開発が中心であろう。

銘柄選択によるプラスアルファの推定モデルを構築するには、ロバストなアルファ値が推定できるモデルと品質の高い原データのインプットが求められる。

CAPM のマーケットモデル ((1) 式) を前提とすると株式ポートフォリオの期待リターン($E(r_i)$)の源泉はリスクフリーリターン(r_f)とリスクプレミアム($\beta(\cdot)$)である。

$$r_i = \alpha_i + \beta_i r_M + \epsilon_i \quad (1)$$

$$E(r_i) = r_f + \beta_i \times (E(r_M) - r_f) r_M \quad (2)$$

リスクフリーリターンは、安全資産（国債、預貯金等）から得られるリターンであり、 β がゼロであれば期待リターンとリスクフリーリターンは等しくなる。

裁定価格理論（APT (Arbitrage Pricing Theory)）での古典的なノー・アービトラージ仮説は、個別証券のリターンが共通リスクファクターへのエクスポージャーの線形関数であるとした。

ここでのリスクプレミアムとは、株式に投資することによって得られる追加的なリターンである。またアクティブリターンとは、優れた銘柄選択能力により得られる追加的なリターンをさす。

そこではシングルファクター、マルチファクターの差はあるもののリスクプレミアムの係数であるベータの推定方法の精度が重要になる。

これまでリスクとリターンの関係から大きなリスクをとることが大きなリターンを得ることにつながるとされてきた。ところが近年ボラティリティパズルと呼ばれる理論とは逆の現象が指摘されるようになってきている[1]。

伝統的な投資理論では、ハイリスク・ハイリターン、ローリスク・ローリターン、なのに対して、観

察される現象は、ハイリスク・ローリターン、ローリスク・ハイリターンとなる場合である。

この要因としてリスクプレミアムが十分に特定されていない説明変数の数を含めた変数選択の問題なのか、アノマリーが原因となる一時的な現象であるのかで見解が分かれてきた。

本稿では、Stroyny, Wilding, のリサーチ[3]をもとにリスクプレミアム v s アノマリーの議論とは別の視点となる統計的手法による α 、 β の推定精度向上について議論する。推定バイアスの存在を確認し、アルファ獲得の可能性を向上させる方法について検討する。

2. 線形ファクターモデル

2.1 アルファとは何か

インデックを対ベンチマークとしてプラスアルファを狙う場合（相対リターン）と投資開始時点よりも資産の評価額を拡大する（期初の水準をベンチマークとしてアルファを狙う）場合（絶対リターン）に大きく分けられる。

アウトオブサンプルに基づいて将来の期待リターンを予測できれば、その銘柄に対して計算された評価値の高い順番にポートフォリオを組むことでアルファが獲得できるはずである。

筆者はかつてアルファモデルの開発に取り組んだ経験がある。一番のキーとなるのはアルファ値の推定精度である。そのため過去の局面ごとにアルファ値を使ったシミュレーションを行い、上昇相場でも下降相場でもアルファ（相対リターン）を獲得できるモデル開発を目指した。

パフォーマンスの良し悪しは、アルファ値の予測力に加えて最適化の条件設定とも関連する。アルファ値（期待リターン）を最大化しつつ、ベンチマークから離れないパフォーマンスを実現する最適化は長年テーマとなっていた。

2.2 同時推定バイアス（CEB）

APT では個別銘柄の期待リターンは線形ファクタープロセスによって生成されるとしている。

線形ファクターモデルの発展は、同じデータセットからアルファ（パフォーマンス評価値）とベータ（リスク指標）を推定するときに発生する同時推定バイアス（CEB）の課題に直面することになる。

この課題はそれに取り組むことによって同時推定バイアス（CEB）を避けるための推定手法の開発につながったとのプラスの側面がある。

ただ同時推定バイアス（CEB）についての基本的

な原因については十分に周知されているとは言い難い。

APT では、 r は n 銘柄の株式リターンであり、次の線形ファクタープロセスから生成される。

$$r = \mu + Bz + e \quad (1)$$

ここで B は $(n \times k)$ のファクター β の行列、 μ は個別銘柄 n 個の期待リターンと k 個のシステムティックファクターとなり、 e は n 個の残差（銘柄固有）リターンとなる。

定義より $E[z] = 0$ と $E[e] = 0$ である。株式固有リターンはお互い無相関であり ($E[e, e'] = 0$)、システムティックファクターとも無相関 ($E[e, z'] = 0$) である。期待リターンとシステムティックファクターリターンとの関係は次のように記述できる。

$$E[r] = \mu + r_0 + B\pi + \alpha \quad (2)$$

ここで π は k 個のシステムティックファクターのリスクプレミアムとなり、 r_0 はリスクフリーリターンである。APT における無裁定の前提は期待リターンとリスクエクスポージャーの関係が $\alpha = 0$ のとき成り立つ。

最近アルファを獲得することがますますむづかしくなっている状況から、ここ数年市場ベータ以外のリスクファクターにエクスポージャーをもつインデックスで運用するスマートベータとよばれる運用手法に注目が集まるのは理解できる。

2.3 最小二乗回帰（OLS）

最小二乗回帰（OLS）は、残差分散が経時的に同一であることを仮定している。しかし実際には Connor, Korajczyk, and Linton (CKL) が議論しているが、残差リターンは時間によって変化する。

そのため彼らは時系列不均一分散を近似したダイナミックなファクターモデル（単共通コンポーネントモデル）を開発している。

ただ、このモデルの仮定はすべての個別銘柄の残差分散が時系列的に同一の動きをすることにある。そのため実際の個別銘柄の残差分散が時系列に不均一となる動きをとらえていない。

個別銘柄の残差分散の変動は、個別銘柄ごと、時間的にも異なる点から実務的に適用する場合には注意が必要となる。

不均一分散の誤差項のあるパターンから得られる最小二乗回帰（OLS）による標本平均とベータがバイアスのあるリスクプレミアム推定値となる例を示す。

これはいわゆる同時推定バイアス (CEB) と呼ばれる。過去の個別銘柄のリターンの不均一分散のパターンを提示すると同時にそのバイアスを消去するロバストな推定プロセスを示す。


3. 推定バイアス

3.1 外れ値の効果

Stroyny は、最小二乗 (OLS) 推定における不均一分散をもつ残差、誤差の特定のパターンが標本平均とベータに相関を発生させることを示した。

ベータと標本平均は誤ったリスクリターントレードオフを生成し、それによりアルファの偏った推定値を算出することになる。

実際、線形ファクターモデルにおける最小二乗推定 (OLS) の残差が均一分散との仮定と一致しない事例は多い。



(図 1) β を推定する際の外れ値の効果

グラフ (図 1) の Y は 30 変数の正規乱数を 100 期間生成して、次に 1 個のファクターを自由度 3 の T 分布で 100 期間発生させる。

1 個のファクターの残差分散を通常の残差分散の 20 倍として乱数を生成している。残差分散にレバレッジがかかった場合のシミュレーションである。

そこに引かれた回帰直線は、1 期間の外れ値をプラスとしてとる場合には右肩上がりの回帰直線となり、マイナスの外れ値をとる場合には右肩下がりの回帰直線となる。

よって真の β が 0 との前提があるにもかかわらず極端な外れ値があると、その前提が影響を受けることがわかる。

3.2 「相関を持った変数誤差」(CEIV)


単一の過去のデータセットから標本平均とベータ

の最小二乗 (OLS) 推定を実行すると、潜在的に各変数の誤差間に相関が生じる Correlated Errors-In-Variables (CEIV) 「相関を持った変数誤差」の偏りが生じる。

ベータを推定するための過去データのグループと標本平均を推定する過去データのグループに分割する等の同時推定バイアス (CEB) を避けるための多くの推定方法が考案されてきたが、これらのアプローチはそれぞれのケースで利用可能な情報が半分となり非効率である。

(図 2) では、相関を持った変数誤差の例を示している。横軸に最小二乗回帰による β (リスク) と縦軸に期待リターン (リターン) をとり、データをプロットして回帰直線 (OLS) を引くと傾きがプラスとなっている。

リスクプレミアムの推定に本来はリスクとリターンのトレードオフが存在するとの前提関係が、疑似的なプラスのトレードオフ関係が観察される結果となっている。



(図 2) 「相関を持った変数誤差」の偏りの例

4. 統計的なソリューション

4.1 収益データ

(図 3) は、時系列プロットである。2 つの分散成分 (Scale1, Scale2) の推定結果と米国の四半期の週次の収益リリースに対する反応を示す。

分散成分 1 (Scale1) のピークの値は期間 66 のところであり、2008 年 10 月 10 日 S&P500 指数が週次で最大の下落を記録したときに対応している。グラフをみると 13 週ごとに分散の大きさがピークとなっていることが観察される。業績発表のグラフと重ねてみると分散が上昇するタイミングは収益発表のピークと一致している。

収益発表とは、銘柄固有の情報であり、発表され

ることにより残差分散が影響を受けることは自然である。

固有ファクターの最大ファクターが 66 週目になっていることから、単一の分散スケールが 3 つの最大ファクターレバレッジにそっているのは先のシミュレーションと平仄があう。

これらのことからリスクプレミアムの OLS 推定法による時系列の推定値にはシミュレーションで示した同時推定バイアス (CEB) が存在する可能性が高いと判断できる。

4.2 統計的なソリューション


それでは、上記のバイアスを回避する方法はあるのだろうか。その一つの案としては、OLS (最小二乗回帰分析) の代わりに WLS (重み付き最小二乗回帰分析) を利用する方法である。

(図 3) の Scale1 は Connor, Korajczyk, and Linton (CKL) の単成分分散モデルに週次のデータを適用して近似した結果であり、Scale2 は線形ファクターモデルとして多成分分散モデルを適用した結果である。

多成分分散モデルは、3 個の固有ファクターに 2 成分正規混合残差モデルを組み合わせて最尤法により推定している。

グラフをみると四半期の収益発表が残差分散に影響を与え、単成分分散モデルでは、そのショックを緩和できている。ただ 2008 年 10 月 10 日 S&P500 の下落時には最大の分散の変動を受けている。つまり単一モデルでは、避けることができない残差分散ショックがあることがわかる。

一方で AL Stroyny が考案した多成分分散モデルでは、2008 年 10 月 10 日のショックを吸収できていることが観察できる。その時点以外の 4 半期の収益発表のショックの影響も緩和できている。



(図 3) 2 つの分散成分 (Scale1, Scale2) と米国四半期の週次の収益リリースに対する反応

5. おわりに

本稿では、残差分散の変動が β に影響して、 α の推定値の精度を低下させている可能性をシミュレーションにより例示した。

そしてそれを解決するためにひとつの統計手法として多成分分散モデルの提案を行っている。

四半期の収益発表の季節変動とそれに加えて大きなマーケットからのショックというアノマリーを統計モデルにより捕捉する可能性を示唆している。

謝辞

Alvin L. Stroyny, Ph.D. と Timothy C. Wilding, Ph.D が彼らの研究成果について情報共有してくれたことに感謝したい。また David Androsone が本稿の作成にあたりサポートしてくれたことに感謝する。

参考文献

- [1] 加藤康之, スマートベーター新時代の投資理論ー, 応用経済時系列研究会第 23 回談話会資料, 2016 年 2 月 16 日
- [2] <http://www.bloomberg.com/news/articles/2015-02-27/bridge-water-is-said-to-start-artificial-intelligence-team>
- [3] Stroyny., Wilding., Why Robust Alpha (and Beta)?, discussion paper, unpublished, (2016)

インターネット株式掲示板にみるカスケード効果と初期収益率

月岡靖智^{1*}

¹ 関西学院大学商学部

Abstract: 本稿は、投資家心理のカスケードが IPO (新規株式公開) における初期収益率に与える影響を検証する。投資家心理のカスケードを測定するために、インターネット株式掲示板における高い中心性を有する中心投資家 (投稿者) の強気度合に焦点を当てる。ネットワーク指標である中心性は、IPO 企業毎のインターネット株式掲示板の書き込みからグラフ理論に基づき測定する。2001 年から 2010 年までの IPO 企業 654 社を用いて検証した結果、中心投資家が強気であるほど、全体の投資家心理が強気であり、かつ初期収益率が高いことを発見した。

1. はじめに

本稿は、投資家心理が他の投資家心理へと伝播する投資家心理のカスケードを IPO 前の Yahoo! Japan Finance 株式掲示板 (以下、「Yahoo! 掲示板」) データを用いて確認し、この投資家心理のカスケードが初期収益率に与える影響を検証する。

IPO における初期収益率の原因として情報カスケードを Welch (1992) は示唆している。しかし、実際の IPO、特に現在のブック・ビルディング方式での IPO において、投資家は先に申し込みを行った投資家または他の投資家の需要情報や意見を知ることができないため情報カスケードが起きにくいと考えられる (忽那, 2008; 岡村, 2013)。

本稿の目的は、「Yahoo! 掲示板」における、企業毎の IPO 前の書き込みを用いることで投資家心理のカスケードを測定し、投資家心理のカスケードが初期収益率に与える影響を検証することである。IPO 株式に対する投資家心理は、テキストマイニングの手法を用いて「Yahoo! 掲示板」の書き込みから計測する。加えて、中心となる投資家は、「Yahoo! 掲示板」の書き込みが時系列であることと、掲示板データに含まれる返信元の投稿番号を利用し、ネットワーク分析を適用することで特定する。

2001 年から 2010 年までの IPO 企業 654 社を用いて検証した結果、中心性の高い投資家が強気であるほど、全体の投資家心理が強気であり、かつ初期収益率が高いことを発見した。本稿の貢献は、カスケードの観察が困難であると考えられていた IPO 市場において、インターネット掲示板の書き込み情報から投資家心理と投資家のネットワークを計測し、投資家心理のカスケードが初期収益率の一因であるこ

とを示したことにある。

本稿の構成は以下のとおりである。第 2 節では、「Yahoo! 掲示板」のデータ、データからのネットワークの構築および投資家心理の測定について説明する。第 3 節では、先行研究をレビューし検証仮説を設定する。第 4 節では、データソースについて説明する。第 5 節では、実証結果を示す。第 6 節では、本稿の総括を行う。

2. 掲示板情報とネットワーク

2.1. 掲示板情報とネットワーク

「Yahoo! 掲示板」データには、投稿番号、書き込み日時、投稿者 ID、返信元の投稿番号、タイトルおよびコメントが含まれている。「Yahoo! 掲示板」データの特徴の 1 つとして、企業毎に 1 つのスレッドが設けられている。

本稿では、スレッド毎の書き込みを用いてネットワークを構築する。グラフ理論において、ネットワークは頂点 (node) と、頂点と頂点の間をつなぐ辺 (edge) で構成される (Newman, 2003, 2010)。ここでは、投稿者を頂点、投稿者間の繋がりを辺として用いる。投稿者間の繋がりは書き込みの順番と返信元の投稿番号による書き込み間の返信を基に特定する。

ある IPO 企業の上場前のスレッド情報を用いて図示したネットワークグラフを図 1 に示す。図 1 は、一部の投稿者がスレッドにおけるネットワークの中心にいることを示している。

本稿では、ネットワーク分析を用いることで中心的な投稿者を特定するための点中心性を測定する。Hochberg et al. (2007) を参考に中心性指標には、次数

* 連絡先: 関西学院大学商学部

〒662-8501 兵庫県西宮市上ヶ原一番町 1-155

E-mail: tsukioka@kwansei.ac.jp

中心性 (degree), 近接中心性 (closeness) および固有ベクトル中心性 (eigenvector) を用いる. まず, 度数中心性による点中心性の定義は以下のとおりである.

$$C_d(p) = \sum_{q=1}^n a_{p,q} \quad (1)$$

ここで p は投稿者, q は他の投稿者, a は投稿者 p に接続している辺の数を示している. つまり, 度数中心性は投稿者が行った書き込みと受けた返信の数の合計を示している. 多くの書き込みおよび返信を受けた投稿者の度数中心性は高い.

近接中心性による点中心性の定義は以下のとおりである.

$$C_c(p) = \frac{1}{\sum_{q=1}^n d_{p,q}} \quad (2)$$


ここで, d は他の頂点までの距離を示している. 近接中心性による点中心性は, 他の投稿者までの距離の合計で示される. ネットワークの中心に位置し, 他の投稿者との距離が短い投稿者ほど近接中心性は高くなる.

固有ベクトル中心性による点中心性の定義は以下のとおりである.

$$C_e(p) = \frac{1}{\lambda} \sum_{q=1}^n a_{p,q} C_e(q) \quad (3)$$

これら中心性指標で測定した点中心性の上位 5% の投稿者を中心投資家 (central investor) と定義する. 図 1 における中心投資家は, どの中心性指標で測定しても "ser" と "mki" である.

図 1 ネットワークグラフの例



2.2. 投資家心理の測定

本稿では, IPO 企業毎のスレッドから構築したネットワークにおける点中心性の上位 5% に含まれる中心投資家をカスケードの起点とする. 中心投資家の投資家心理およびスレッド全体の投資心理を測定するために, テキストマイニング手法を用いて彼らの書き込みを強気, 弱気または中立に分類し, 強気度合を測定する. テキストマイニングによる書き込みの分類方法の詳細は, Tsukioka et al. (2015) を参照されたい. 強気指数 (bullishness index) は, Antweiler and Frank (2004) に従い以下の (4) 式で計算する.

$$\text{bullishness index}_i = \text{Ln} \left(\frac{1 + \text{the number of bullish messages}_i}{1 + \text{the number of bearish messages}_i} \right), \quad (4)$$

中心投資家の強気指数 (bullishness index_{central investor}) は, 中心投資家の書き込みのうち強気または弱気に分類した書き込み数に基づき計算する. スレッド全体の強気指数 (bullishness index_{thread}) は, スレッドの書き込みのうち強気または弱気に分類した書き込み数を用いて計算する. bullishness index がプラスであれば投資家心理は強気であり, マイナスであれば投資家心理は弱気である.

例えば, 図 1 の例で用いた中心投資家である "ser" と "mki" による書き込み数は 11 件あり, この書き込みの分類結果は強気書き込み数が 0 件, 弱気書き込み数が 1 件である. よって, この企業の中心投資家の投資家心理である bullishness index_{central investor} は -0.693 であり, 中心投資家の投資家心理は弱気である. また, スレッド全体としては, 強気書き込み数が 3 件, 弱気書き込み数が 6 件であり, スレッド全体の投資家心理である bullishness index_{thread} は -0.560 であり, スレッド全体の投資家心理も弱気である.

3. 先行研究と仮説の設定

投資家が他の投資家の行動または口コミ等の外部情報から影響を受けることは広く知られている. Banerjee (1992) は, 連続的な意思決定において, 投資家が先行する投資家の行動を模倣し, その後の投資家も同様に模倣を行うためにカスケードが生じることを理論的に示している. Shiller and Pound (1989) は, 投資家の投資意思決定が口コミ等から影響を受けていることを質問調査で明らかにしている. Kuran and Sunstein (1999) は, 人の信念が取得可能な情報によって形作られる取得可能性のカスケード (availability cascade) を指摘している. さらに, Welch (1992) は, IPO において投資家が他の投資家の株式購入の見送りを知ることで, その株式の購入を見送

るといふ負のカスケードを防ぐために、発行者の行う低い公開価格の設定が高い初期収益率の要因であると指摘している。加えて、投資家は自身の私的情報を無視しても先行する投資家の決定に追随するので、カスケードが引き起こされることを指摘している。

本稿では、IPO において先行する投資家の意思決定や需要情報を直接的に測定することができないため、「Yahoo! 掲示板」のデータから投資家心理のカスケードを測定する。ただし、「Yahoo! 掲示板」内の投稿者間の繋がりは極めて希薄であると考えられるが、Miller et al. (2011) および Kramer et al. (2014) は、「Yahoo! 掲示板」と同じく投稿者間の直接的なコミュニケーションに限られるインターネットソーシャルメディアにおいて、心理の伝播が生じることを示している。

上記の研究から「Yahoo! 掲示板」においても、投資家心理は他の投資家心理に影響を与えられられる。つまり、ネットワークの中心にいる投資家の心理は、その周辺およびネットワーク全体の投資家心理に影響を与えられられる。また、Tsukioka et al. (2015) は、投資家心理が高い初期収益率を引き起こす一因であることを示している。全体の投資家心理の発端である中心投資家の投資家心理が初期収益率の要因であると考えられる。よって、以下の仮説 1 と仮説 2 を設定する。

仮説 1：ネットワークの中心にいる投資家の心理は、ネットワーク全体の投資家心理とプラスの関係にある。

仮説 2：ネットワークの中心にいる投資家の心理は、初期収益率とプラスの関係にある。

4. データについて

本稿は、Tsukioka et al. (2015) で取得した 2001 年から 2010 年までに上場した企業の「Yahoo! 掲示板」データを用いて分析を行う。また、財務データ、株価データおよび企業情報に関しては『日経 NEEDS-Financial QUEST (日経メディアマーケティング株式会社)』から取得する。IPO 日およびブック・ビルディング期間に関しては、『トレーダーズ・ウェブ』のウェブサイトおよび『eol』の目論見書等から取得する。本稿における最終サンプルは、上記要件を満たす 654 社で、最終的な分析対象である書き込み数の合計は、129,676 件である。

5. 分析結果

表 1 は、仮説 1 を検証した結果を示している。次数中心性、近接中心性および固有ベクトル中心性のそれぞれの中心性指標に基づいた *bullishness index* *central investor* の係数は有意にプラスに推定されている。この結果は、中心投資家が強気であれば、他の投資家も強気になることを示しており、仮説 1 を支持している。ただし、係数が 1 を超えていないため、中心投資家の投資家心理が増幅しているわけではなく、緩やかに波及していると考えられる。

表 1 中心投資家心理と全体の投資家心理

Dependent variable: <i>Bullishness index</i> <i>thread</i>			
<i>Bullishness index</i> <i>central investor</i>			
degree	0.423 ***		
	(14.378)		
closeness		0.417 ***	
		(13.761)	
eigenvector			0.347 ***
			(11.204)
<i>Market</i>	0.000	0.001	0.002
<i>condition</i>	(0.116)	(0.495)	(1.105)
<i>Ln (assets)</i>	-0.064 ***	-0.065 ***	-0.077 ***
	(3.459)	(3.404)	(3.890)
<i>Debt</i>	0.102	0.122	0.058
<i>to assets</i>	(0.970)	(1.141)	(0.536)
<i>Ln (age+1)</i>	0.051	0.100 ***	0.069 **
	(1.618)	(3.150)	(2.168)
<i>Intercept</i>	0.297	0.098	0.372 **
	(1.512)	(0.505)	(1.941)
<i>Adj. R²</i>	0.276	0.244	0.184
<i>N</i>	654	654	654

表 2 は、仮説 2 を検証した結果を示している。次数中心性、近接中心性および固有ベクトル中心性のそれぞれの中心性指標に基づいた *bullishness index* *central investor* の係数は有意にプラスに推定されている。この結果は、中心投資家が強気であるほど、初期収益率が高くなることを示しており、仮説 2 を支持している。また、コントロール変数である *Market Condition* の係数が有意にプラスに推定されており、市況が良好であるほど初期収益率が高いことを示している。

表 2 中心投資家心理と初期収益率

Dependent variable: <i>Initial return</i>			
<i>Bullishness index</i> <small>central investor</small>			
degree	15.370 ***		
	(3.546)		
closeness		13.837 **	
		(2.732)	
eigenvector			13.311 **
			(2.935)
<i>Market condition</i>	1.464 ***	1.489 ***	1.529 ***
	(5.213)	(5.310)	(5.434)
<i>Price revision</i>	0.875	0.901	0.851
	(1.407)	(1.437)	(1.350)
<i>Ln (assets)</i>	-16.531 ***	-16.599 ***	-17.007 ***
	(5.521)	(5.498)	(5.580)
<i>Debt to assets</i>	-21.780	-21.282	-23.343
	(1.183)	(1.154)	(1.271)
<i>Ln (age+1)</i>	-11.042 **	-9.244 *	-10.427 **
	(2.220)	(1.897)	(2.104)
<i>Intercept</i>	215.336 ***	208.964 ***	218.092 ***
	(8.110)	(7.781)	(8.080)
<i>Adj. R²</i>	0.263	0.260	0.260
<i>N</i>	654	654	654

6. おわりに

本稿は、「Yahoo! 掲示板」の書き込み情報を用いて投稿者ネットワークの中心にいる中心投資家を特定し、中心投資家を起点とする投資家心理のカスケードの有無および投資家心理のカスケードが初期収益率に与える影響を検証した。カスケードが IPO における高い初期収益率の一因であるとする指摘もあったが、これまで IPO 前に投資家が他の投資家の行動や意見を観察できないためにカスケードは起こりにくく、カスケードが存在するとしても検証が困難であると考えられてきた。本稿の意義は、「Yahoo! 掲示板」における IPO 前の書き込みを用いることで、これらの問題を克服し、投資家心理のカスケードと初期収益率の間の有意な関係を明らかにしたことにある。

検証の結果、中心投資家の投資家心理とスレッド全体の投資家心理にはプラスの関係があることを発見した。さらに、中心投資家の投資家心理と初期収

益率の間にはプラス関係があった。これらの結果は、中心投資家の投資家心理が他の投資家に波及し、この投資家心理のカスケードによって IPO における高い初期収益率が引き起こされていることを示唆している。

謝辞

本研究は、JSPS 科研費 26885065 の助成を受けたものです。

参考文献

- [1] Antweiler, W., and M. Z. Frank: "Is All That Talk Just Noise? The Information Content of Internet Stock Message Boards," *Journal of Finance*, Vol. 59, No. 3, pp. 1259-1294 (2004)
- [2] Banerjee, A. V.: "A Simple Model of Herd Behavior," *Quarterly Journal of Economics*, Vol. 107, No. 3, pp. 797-817 (1992)
- [3] Easley, D., and J. Kleinberg: *Networks, Crowds, and Markets: Reasoning about A Highly Connected World*, Cambridge University Press (2010)
- [4] Hanley, K. W.: "The Underpricing of Initial Public Offerings and the Partial Adjustment Phenomenon," *Journal of Financial Economics*, Vol. 34, No. 2, pp. 231-250 (1993)
- [5] Hochberg, Y. V., A. Ljungqvist and Y. Lu: "Whom You Know Matters: Venture Capital Networks and Investment Performance," *Journal of Finance*, Vol. 62, No. 1, pp. 251-301 (2007)
- [6] Kramer, A. D. I., J. E. Guillory and J.T. Hancock: "Experimental Evidence of Massive-scale Emotional Contagion through Social Networks," *Proceedings of National Academy of Sciences of the United States of America* (2014)
- [7] Kuran, T. and C. R. Sunstein: "Availability Cascade and Risk Regulation," *Stanford Law Review*, Vol. 51, No. 4, pp. 683-768 (1999)
- [8] Miller, M., C. Sathi, D. Wiesenhal, L. Leskovec and C. Potts "Sentiment Flow through Hyperlink Networks," *Proceeding of Fifth International AAAI Conference on Weblogs and Social Media* (2011)
- [9] Newman, M. E. J.: "The Structure and Function of Complex Networks," *SIAM Review*, Vol.45, No. 2, pp.167-256 (2003)
- [10] Newman, M. E. J.: *Networks An Introduction*, Oxford University Press (2003)
- [11] Shiller, R. J.: "Conversation, Information, and Herd Behavior," *American Economic Review*, Vol. 85, No. 2, pp.

181-185 (1995)

- [1 2] Shiller, R. J. and J. Pound: “Survey Evidence on Diffusion of Interest and Information among Investors,” *Journal of Economic Behavior and Organization*, Vol.12, No. 1, pp.47-66 (1989)
- [1 3] Tsukioka, Y., J. Yanagi and T. Takada: “Investor Sentiment Extracted from Internet Stock Message Boards and IPO puzzles,” Working Paper, Osaka City University (2015)
- [1 4] Welch, I.: “Sequential Sales, Learning, and Cascades,” *Journal of Finance*, Vol. 47, No. 2, pp. 695-732 (1992)
- [1 5] White, H.: “A Heteroskedasticity-Consistent Covariance Matrix Estimator and a Direct Test for Heteroskedasticity,” *Econometrica*, Vol. 48, No. 4, pp. 817-838 (1980)
- [1 6] Wu, W., H. Chang, S. Suardi and Y. Chang: “The Cascade Effect on Lending Conditions: Evidence from the Syndicated Loan Market,” *Journal of Business Finance and Accounting*, Vol. 40, No. 9-10, pp. 1247-1275 (2013)
- [1 7] 岡村秀夫: 『日本の新規公開市場』, 東洋経済新報社 (2013)
- [1 8] 忽那憲治: 『IPO 市場の価格形成』, 中央経済社 (2008)
- [1 9] 丸山健・梅原英一・諏訪博彦・太田敏澄: 「インターネット株式掲示板の投稿内容と株式市場の関係」, 『証券アナリストジャーナル』, Vol.46, No. 11-12, 110-127 頁 (2008)

文書の分散表現と深層学習を用いた日銀政策変更の予想

Forecast System for the BoJ's Monetary Policy Change by Distributed Representation of Documents and Deep Belief Network

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

¹ Economic Research, Credit Suisse Securities (Japan) Limited

Abstract: The author utilized text-mining and deep-learning technics to forecast a monetary policy change by the BoJ. More specifically, the classifier of the BoJ's documents was developed, which picks up the document containing any trait of previously-experienced precursor for monetary policy change. Such classifier was constructed by obtaining distributed representation of documents via Doc2Vec and feeding them into Deep Belief Network with economic time-series data. The back-test for the period from Jan 2014 to Jan 2016 showed a fair performance of the classifier to send precursory signals against two cases of additional monetary easing.

1. はじめに

日本銀行による金融政策の変更は、金融市場における重大な関心事のひとつである。特に 2013 年 4 月の黒田総裁就任以降、その注目度は更に高まっている。異次元規模の資産購入（2013 年 4 月）とその拡大（2014 年 10 月）、更にはマイナス金利の導入（2016 年 1 月）と、金融市場の価格形成を歪めるほどの大掛かりな政策変更が行われたためだ。

黒田総裁体制の日本銀行は、金融政策の変更を市場が十分に予期しないまま行うため、市場参加者からサプライズ志向と看做されている。こうした方針は、政策変更のインパクトを強める一方で、市場が予想する政策の方向性が安定せず、様々な市場価格のボラティリティを高める一因となっている可能性がある。換言すれば、日銀の公表する文書や総裁の発言を、言葉通り解釈しているだけでは、日銀がいつ何をするつもりなのか予期できない、という不確実性のコストが生じている。

したがって、もし従来通りの人間による文書読解では見落としてしまうようなパターンが、まだ日銀の政策変更に残されているならば、それを何らかの手法を用いて捕捉することで、市場機能の安定化にある程度寄与できるだろう。

そのようなパターンを抽出する手法として、近年、

画像認識等での高い実績が注目されている深層学習の技術を試すことは有益だと思われる。

深層学習の手法は、金融市場分析でも少なからず応用が進んでいる。例えば、[1] Chao, et al.は、深層信念ネットワーク（DBN: Deep Belief Network）を為替レートの予想に用いた研究だが、連続値をとる時系列データに深層学習の手法を用いた初期の例として注目されている。また、[2] 小牧・白山は、同様の手法に改良を加え、日経平均株価の予想に用いている。

他方で、テキスト・データによる機械学習（自然言語処理）を金融市場分析に用いた研究も盛んである。例えば、[3] 和泉 他は、日銀の金融経済月報から共起解析・主成分分析・回帰分析を組み合わせた CPR 法と呼ばれる方法で特徴を抽出し、為替、債券、株式市場の価格変動を予想した。また、[4] 吉原 他は、金融市場関連のニュースを深層学習モデルの一種である RNN-RBM（Recurrent Neural Networks Restricted Boltzmann Machine）に読み込ませ、株価の予想に応用した。また、[5] 片倉・高橋は、株式市場ニュースから CBOW (Continuous Bag of Words) によって単語の分散表現を獲得し、株式市場のファクター・リターンとの相関を分析している。

これらの先行研究は、深層学習の応用やテキスト・データの活用が金融市場分析に対しても総じて有用であることを示している。一方で、いずれの研究も、その目的は市場価格の変動を予想することが主であり、金融政策の変更を直接に扱うことは一般

* 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

的でない。

こうした背景から、本稿では、日銀の政策決定変更のパターンを、日銀が公表する文書を用いた深層学習によって抽出し、政策変更の予想に役立てることを新たに試みる。

2. 分析手法

日銀が公表した文書を、政策変更直前の特徴を有する (1) か否 (0) かに分類する。すなわち、[6] Le and Mikolov によって提案された文章の分散表現を獲得する手法と、深層信念ネットワーク (deep belief network; DBN) を組み合わせ、新たに入力された日銀の文書が、次回の決定会合で金融政策の変更を行った過去ケースと同様の特徴を有するか否か、判別するための分類器を学習する。その際に、テキスト・データだけでなく、マクロ経済状態を表す時系列データを組み合わせて用いる。

2.1 Doc2Vec による文章分散表現の獲得

[6] Le and Mikolov は、単語だけでなく単語が属する文章の分散表現 (文章ベクトル) を獲得する手法を提案している。Doc2Vec はその手法を実装したモジュールである。

単語の分散表現 (単語ベクトル) を獲得する手法としては、[7] Mikorov, et al. で提案された CBOW (Continuous-Bag-of-Words) と Skip-gram の精度が高いことが知られ、近年注目を集めている。これらの実装は Word2Vec というモジュールとして公開されているが²、Doc2Vec はその拡張版という位置付けである³。

Doc2Vec のデフォルト手法である Distributed Memory Model of Paragraph Vectors (PV-DM) は、単語のまとまりである文章 (Paragraph) に ID を付し、その ID を単語と同じベクトル空間に配置する (文章ベクトルを構成)。この際、文章ベクトルは、設定した文脈窓に後続する単語をより正確に予想できるように学習される。この仕組みを示したのが次図 1 である。すなわち、文脈 $w(t)$, $w(t+1)$, $w(t+2)$ とそれらが属する文章の ID を入力とし、後続の単語 $w(t+3)$ を出力としたニューラル・ネットワークを、トレーニング・データの文章全域にわたって学習することで、単語と文章の分散表現が得られる。

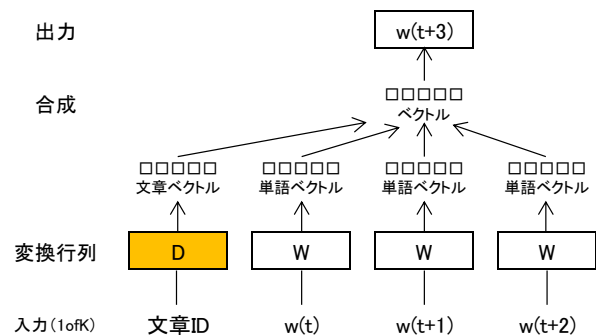


図 1: PV-DM の概略図

2.2 DBN を用いた分類器の学習

続いて、Doc2Vec によって獲得した文章ベクトルを、経済時系列データと合わせて分類器の入力として利用する。

本稿では、線形分類器 (ロジスティック回帰) の内部を、CRBM (Continuous Restricted Boltzmann Machine) で多層化した深層信念ネットワーク (DBN) を用いる。CRBM は [8] Chen, et al. によって提案され、経済時系列データなどの連続値を扱えるように RBM (Restricted Boltzmann Machine) を修正したものである。

この CRBM を積層し、出力層をロジスティック回帰 (LR) とした深層信念ネットワークを、一般的な深層学習のプロトコルに倣って、プレトレーニングした後、誤差逆伝播法によってファインチューンし、学習を行う。同様の手法は、為替レートの予想を行った [1] Chao, et al. や日経平均株価の予想を行った [2] 小牧・白山などに見られる。

本稿では、(1) 経済時系列データをまとめたベクトルとテキスト・データから作成した文章ベクトルを、共に多層 CRBM に入力して使用するケースと、(2) 多層 CRBM には文章ベクトルだけを入力し、経済データ・ベクトルは最後のロジスティック回帰の層に直接入力するケースを推計する。また、比較対象として (3) DBN を用いずに、文章ベクトルと経済データ・ベクトルを共にロジスティック回帰に直接入力したケースも試している。

これらの 3 つのモデル (図 2) について、日銀の政策変更予想のパフォーマンスを比較していく。

² <https://code.google.com/p/word2vec/>

³ なお、本稿では Doc2Vec の Python 実装である Gensim パッケージを用いている。

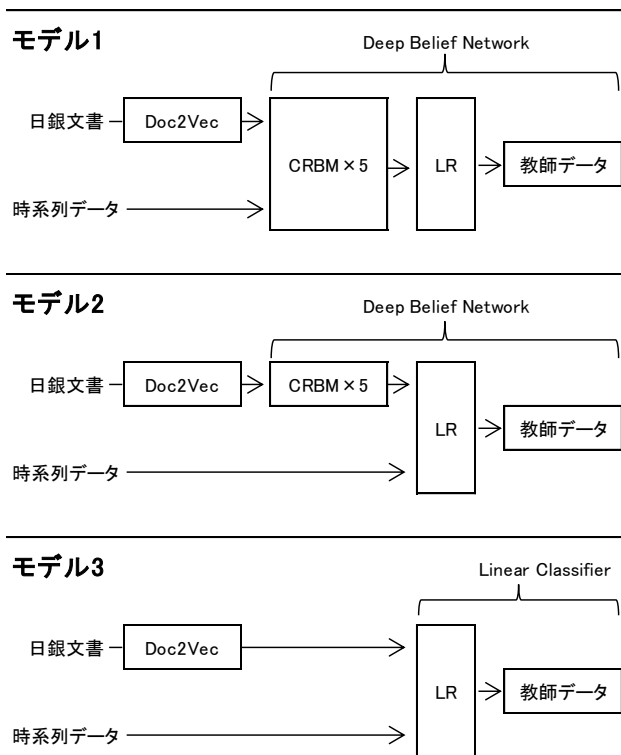


図 2: モデル全体の概略図

3. 使用データとパラメータ設定

使用したテキスト・データは、日本銀行がウェブサイト上に公開⁴している 2011 年 1 月～2016 年 1 月までの決定会合声明文、金融経済月報、展望レポート、総裁記者会見記録である。

通常、テキスト・マイニングでは、助詞や記号などは出現頻度が高く、かつ、単独で意味を持たないため除去することが多い。今回の分析でも、形態素分析を行い、名詞、動詞、形容詞、形容動詞、のみを用いている。

一方、経済時系列データについては、日銀が政策変更の判断に際して、特に重視していると思われる 5 変数を用いる。すなわち、(1) CPI 前年比の 10% 刈込平均値、(2) CPI (除く生鮮食品) 前年比、(3) CPI 前年比の加重中央値、(4) 日経平均株価の前年比、(5) ドル円レートの前年比である。

ロジスティック回帰の被説明変数となる教師データは、それぞれの文書について、その発表日から見て次回に当たる決定会合で政策変更が決められた場合には 1、そうでなければ 0 としたダミー変数である (以下、政策変更直前ダミーと呼ぶ)。

このとき、教師データと文書データのサンプル数

はマッチしているが、経済時系列データはそうではない。ドル円レートと日経平均については日次データがあるため文書発表日の終値を使用する。また、月次データである CPI については、文書発表日の時点で発表済みの直近値を使用する。

以上のデータセットを、2011 年 1 月～2013 年 12 月までをトレーニング・データとし、2014 年 1 月～2016 年 1 月までをテスト・データとして分割して用いる。

トレーニング・データを用いたモデル学習とテスト・データによる検証の手順をまとめると以下の通りである。

- (1) トレーニング用の文書データを Doc2Vec に入力し、各文書の分散表現を獲得する。この時、分散表現のベクトル次元は 200 とし、文脈窓は 10 語に設定した。
- (2) 文書ベクトルと経済データ・ベクトルを入力とし、政策変更直前ダミーを教師データとした DBN を学習する。このとき、CRBM の積層数は 5 層であり、隠れ層の次元は深くなるにつれて 150、125、100、75、50 と小さくしている。
- (3) テスト用の文書データを Doc2Vec に追加し、文書の分散表現を学習し直す。こうした手順は、実際の運用において文書の発表毎に Doc2Vec モデルを更新することを念頭にしている。
- (4) (3) で得られたテスト期間の文書ベクトルと経済データを、(2) で学習された DBN に入力し、政策変更直前ダミーの外挿理論値を得る。
- (5) この政策変更直前ダミーの理論値と実績値を比較し、モデルを評価する。

4. 分析結果

テスト期間である 2014 年 1 月～2016 年 1 月の間に、日銀による明確な政策変更は、2 度行われた。具体的には、2014 年 10 月 31 日の量的質的緩和の拡大と 2016 年 1 月 29 日のマイナス金利の導入である。

それぞれのモデルが、これらの決定日の直前に公表された文章についてどれだけ明確なシグナルを出すかがパフォーマンス評価のポイントとなる。

推計された 3 つのモデルによる政策変更直前ダミーの外挿理論値を、その実績値と比較したのが図 3 である。テスト期間の平均絶対誤差を計算すると、モデル 1 が 22.9%、モデル 2 が 9.4%、モデル 3 が 39.9% となった。

⁴ <http://www.boj.or.jp/>




図3：政策変更直前ダミーの実績値と理論値

すなわち、テスト期間の平均的なパフォーマンスとしては、モデル2のパフォーマンスが高かった。もともと、図表3から分かるように、モデル2は2016年1月の政策変更前に明確なシグナルを発していたが一方で、2014年10月の政策変更に対しては無反応であった。

他方、モデル1は、2014年10月の政策変更の前後に不要なシグナルを出したために精度が悪いが、2014年10月と2016年1月の両方の政策変更に対し反応を見せていた。

以上のことから、モデル1とモデル2を相補的に

参照することで、過去2回の政策変更の気配を察知できた可能性がある。

なお、モデル3はいずれの緩和にも有用なシグナルを発したとは言い難い。つまり、深層学習を行うことで、単純なロジスティック回帰に比べて予測パフォーマンスが向上していることを確認できた。

5. まとめ

本稿では、日銀による過去の金融政策変更のパターンを、日銀が公表する文書を用いた深層学習によって抽出し、政策変更の予想に役立てることを試みた。

具体的には、Doc2Vecによって文章の分散表現を獲得し、それを時系列データと組み合わせて深層信念ネットワーク(DBN)に学習させることで、新たに入力された日銀の文書が、次回の決定会で金融政策の変更を行った過去ケースの特徴を有するか否か、判別するための分類器を開発した。推定された分類器は、バック・テストの結果、過去2回(2014年10月と2016年1月)の金融政策変更に対して、ある程度有用なシグナルを発していたと言える。

一方、本稿の分析には更なる精度改善の余地が大いにある。用いるデータの種類や、テキスト・データと経済時系列データを同時に扱う際の工夫などによって、予想精度が大きく変わる。

また、より本質的には、日銀の政策変更行動をより構造的にモデル化すべきだろう。つまり、日銀が経済情勢を観察し、政策変更の必要性を評価し、文書を作成して市場に伝達し、政策決定会で合意を図るまでの一連のプロセスを、潜在変数を含んだデータ生成モデルとして備えることが理想である。

参考文献

- [1] Chao, J., Shen, F. & Zhao, J.: Forecasting exchange rate with deep belief networks. 2011 International Joint Conference on neural Networks (IJCNN), pp. 1259-1266, (2011)
- [2] 小牧 昇平, 白山 晋: Deep Belief Networkを用いた日経平均株価の予想に関する研究, 人口知能学会研究会資料, SIG-FIN-012-08, (2014)
- [3] 和泉 潔, 後藤 卓, 松井 藤五郎: テキスト分析による金融取引の実評価, 第24回人工知能学会全国大会論文集, 3H1-OS12a-2, (2010)
- [4] 吉原 輝, 藤川 和樹, 関 和広, 上原 邦昭: 深層学習による経済指標動向推定, 第28回人工知能学会全国大会論文集, 3H3-OS-24a-5, (2014)
- [5] 片倉 賢治, 高橋 大志: 金融市場ニュースの分散表現学習による辞書作成と金融市場分析, 第29回人工知能学会全国大会論文集, 2G5-OS-25b-5, (2015)

- [6] Le, Q., & Mikolov, T.: Distributed representations of sentences and documents. arXiv preprint arXiv:1405.4053v2. , (2014)
- [7] Mikolov, T., Chen, K., Corrado, G., & Dean, J.: Efficient estimation of word representations in vector space. arXiv preprint arXiv:1301.3781. , (2013)
- [8] Chen, H., & Murray, A.F.: Continuous restricted Boltzmann machine with an implementable training algorithm. Vision, Image and Signal Processing, Vol. 150, No. 3, pp. 153-158, (2003)

Comparison among multilingual financial words using the word2vec and clustering with news resources for automatic creation of financial dictionaries

Enda Liu¹, Tomoki Ito¹, and Kiyoshi Izumi

School of Engineering, The University of Tokyo

Abstract: Vector representation of words such as word2vec is an efficient method used in text mining. However, few papers are focusing on the multilingual studies. In this paper we present the comparative study on English and Japanese resources respectively, and then we try to investigate the possible relationship between the two vector models in two languages. We first extract two word2vec models by using news resources of ten years, and then we cluster them basing on their cosine similarity for both Japanese and English respectively. Second, we extract the words related to finance and then derive two dictionaries in two languages. Finally, we make a comparison between these two dictionaries and tempt to Sentiment estimation of a cluster of one language based on similar clusters of other language.

1 Introduction

Financial text mining is a very important part of aspect of the field of data mining and many studies have been done recent years basing on the machine learning and natural language processing. The prediction of stock price basing on the text mining of stock message board is one of the prevalent research topics, where a sentimental dictionary could be derived so that it becomes easy to identify the whether a word or a message contains positive or negative influences to one or multiple stock prices. However, most of the dictionaries are basing on the text resources in only single language and thereby the relationship of the positive-negative score of the words between multiple languages are seldom studied.

On the other hand, the sentimental resources are not balanced among languages. The amount and variety of the sentimental dictionaries in English is considered to be most since it is most commonly used, whereas other languages including Japanese are less professional, especially on some specific area, for instance, regarding to financial market. It becomes a meaningful and promising work to leverage English text resources and dictionaries in order to derive other dictionaries in other languages, such as in Japanese. Furthermore, a system might be developed for automatic creation of financial dictionaries with multilingual text resources basing on this.

In this paper, we make a comparison of the clustering results of two groups of identical words in Japanese and English, after implementing the word2vec [1] algorithm on both English and Japanese financial text resources respectively, attempting to excavate the relationship between them, which might become key factors for

constructing the automatic creation system.

2 Framework of multilingual word clustering

2.1 Preprocessing the text resources

The preprocessing of the data consists of four parts: retrieving, cleaning, tagging and lemmatization of the original text resources.

In this study, we choose a stock message during the period of year 2010, from Stocktwits, a system that is able to automatically collect English information about stock on the Internet. Similarly, we retrieve Japanese financial message board online. Both of the raw data we obtained contain some unsolvable elements, such as special characters, http and email address, typo, and facial expression, and we therefore need to clean them into the original form.

Tagging and lemmatization are then conducted on both text resources, since we need to perform the vectorization of words by means of the Word2vec [1] which requires us to eliminate the possible morphologies in order to derive a reliable model. Tagger, also known as Part-Of-Speech tagger, assigning every element or token appeared in a sentence a label such as noun, verb, adjective, etc. For English text resources, we implement StanfordNLP [2] tool as tagger as well as NLTK [3] as lemmatizer. Lemmatizer is in charge of the transformation of plural nouns, comparative adjectives, paste tense verb and adverb to their base form. Similarly, we employ the MeCab [4] for analyzing Japanese resources during tokenization, tagging and lemmatizer. Furthermore, we remove unnecessary and meaningless semantic elements including determiner, such as “the”, punctuation marks, conjunction, and foreign word in order to train more

accurate word2vec model. The same scheme will also be adopted during the processing the Japanese version.

2.2 Deriving vector representation

Word2vec is a tool developed by Google based on deep learning which provides an efficient implementation of the continuous bag-of-words and skip-gram architectures for computing vector representations of words [1]. In this study, we use this training the word2vec model with the preprocessed English and Japanese text resources respectively, with the dimensionality k of 200, which is considered to be reasonable figure during training.

2.3 Clustering for both languages

In this present stage of our experiments, we select 103 Japanese words that are not only commonly appeared in the stock message board but also considered to be important for prediction of stock price, as well as the 103 identical English words and phrases translated from the Japanese version. Basing on the vector representation generated from word2vec as discussed previously, we then conduct clustering for both Japanese and English word list using K-means with ten centroids ($k=10$). Here we use cosine similarity as the distance function when training the model, since the word2vec model is considered to have the property when we have two groups of words, in which the words have the similar relationship, and therefore the angles of vectors of words matter much.

Before clustering, our 103 word dictionaries are not normalized, consisted of various tense and plurals. Hence we implement the tagging and lemmatizing again, similar to the preprocessing section discussed previously, and then we remove the useless elements.

During the clustering the English word lists, in case of a word that is not included in our trained word2vec model, we remove it directly. In addition, the English word list also contains phrases which will never be involved in our word2vec model since we train the model word by word rather than by phrases. In case of this, a trick is adopted here that we first retrieve the vector representation for each word appeared in the phrases and then we use the summation results of these vectors as the vector representation for the whole phrase, although this method is still worth discussing more, regarding to its rationality.

3 Experiments Results

The piece of clustering results for both Japanese and English shows in the Table 1.

Table 1: Example of English words clustering

Cluster Name	Word	Corresponding Japanese Word	Cluster name of the Japanese word
EN ₁	Consumption tax increase	消費増税	JP ₅
EN ₁	Tax increase	増税	JP ₅
EN ₈	Demand	需要	JP ₁
EN ₈	Growth	伸び	JP ₃
EN ₉	Improvement	改善	JP ₈
EN ₉	Contribution	貢献	JP ₈
EN ₉	Establishment	新設	JP ₁₀

After clustering with centroid $k=10$ for both English and Japanese 103 common word lists, we assign each of the clustered group of words a name. For English clusters, we define the group name EN _{j} where j is from 1 to 10, whereas for the Japanese clusters, we have the group name JP _{i} where i is from 1 to 10. Next we compare their relationship, the probability whether one group is corresponding to another group. To be specific, Each English cluster have corresponded Japanese words with identical meanings, so we count the occurrence frequency of the corresponding clusters of these Japanese words. Table 2 demonstrates these relationships.

We could find that there should be some directly relationship between this clusters. For example, for EN₁ and EN₄, the words belonging to them are all corresponds to JP₅ and JP₄, indicating that it is highly possible to establish relations among those clusters.

Table 2:

Comparison of English clusters and Japanese clusters

Cluster Name [Total number of words in it]	The cluster name and its frequency of occurrence of the corresponding Japanese word with identical English meaning: cluster name [frequency of occurrence]
EN ₁ [2]	JP ₅ [2]
EN ₂ [12]	JP ₅ [4], JP ₁₀ [2], JP ₄ [2], JP ₁ [2], JP ₇ [1], JP ₃ [1]
EN ₃ [2]	JP ₅ [1], JP ₄ [1]
EN ₄ [1]	JP ₄ [1]
EN ₅ [5]	JP ₇ [3], JP ₄ [1], JP ₂ [1]
EN ₆ [7]	JP ₇ [2], JP ₅ [2], JP ₄ [1], JP ₁₀ [1], JP ₈ [1]
EN ₇ [5]	JP ₇ [2], JP ₅ [1], JP ₄ [1], JP ₁₀ [1]
EN ₈ [16]	JP ₅ [6], JP ₁ [4], JP ₇ [2], JP ₄ [2], JP ₁₀ [1], JP ₈ [1]
EN ₉ [40]	JP ₇ [13], JP ₅ [13], JP ₈ [5], JP ₁ [4], JP ₄ [3], JP ₁₀ [2], JP ₉ [1]

4 Future Works

The study discussed in this paper might be considered as the prior study and an attempt for the automatic creation system of financial dictionaries. In this experiment we derive the preliminary results that through vector representative model such as word2vec combining with machine learning algorithms like k-means, it could be concluded that there is a significant relationship between English and Japanese financial text resources, which is highly promising to obtain further expected results contributing to our final goal.

Here we propose several potential improvements for the future experiment:

- 1) Introduce the phrase2vector model that could offer not only single word but also a phrase a vector representation directly.
- 2) Alter the number of centroid for k=10, for instance, to k=5,15,20,25
- 3) Implement other vector representation schemes instead of only word2vec.
- 4) Establish mathematical similarity expressions in order to excavate more latent relationships among multilingual clusters.

References

- [1] Mikolov, T., Sutskever, I., Chen, K., Corrado, G. S., & Dean, J: Distributed representations of words and phrases and their compositionality. Advances in neural information processing systems pp. 3111-3119, (2013)
- [2] Kristina Toutanova, Dan Klein, Christopher Manning, and Yoram Singer. 2003: Feature-Rich Part-of-Speech Tagging with a Cyclic Dependency Network, Proceedings of HLT-NAACL, pp. 252-259, (2003)
- [3] NLTK official site, <http://www.nltk.org/>
- [4] MeCab official site, <http://mecab.sourceforge.net/>