

人工市場での株取引におけるフレーミング効果に従う 投資家エージェントの影響

Zhai Fei[†] Shen Kan[†] 黒田 雄介[†]
並河 悠介[†] 北栄輔[†]

実際の株取引では、人間行動における幾つかの心理的バイアスを考慮しなければならない。本論文では、このうちからフレーミング効果について考える。最初に、RBF ニューラルネットワークを用いて株価を予測する投資家エージェントを定義し、そのようなエージェントからなる人工市場において取引を行い株価の変動を発生させる。人工市場と実際市場の株価変動特性を比較し、フレーミング効果に従う投資家の市場変動への影響を検討する。

Effect of Stock Investor Agent According to Framing Effect to Stock Exchange in Artificial Stock Market

Zhai Fei[†], Shen Kan[†], Yusuke Kuroda[†], Yusuke Namikawa[†]
and Eisuke Kita[†]

Several psychological biases should be taken into consideration in the actual stock exchange. In this paper, we discuss the effect of the framing effect to it. The stock investor agent is defined by using the RBF neural network. The stock exchange by the agents is performed in the artificial market. The characteristics of the stock price fluctuations in the actual and artificial markets are compared in order to discuss the effect to the agents according to the framing effect.

1. 緒論

伝統的なファイナンス理論では、市場の挙動は効率的市場仮説に基づいていると考えられている。しかし、実市場の挙動解析結果などから、実際の市場挙動には必ずしも効率的市場仮説に基づかない現象（アノマリー）が多数みられることが指摘されている。そこで、このような市場挙動を評価するために、市場参加者の認知的バイアスを考慮に入れた「行動ファイナンス理論」が提案されている。行動ファイナンス理論は、投資家における投資行動の意思決定を観察し、どのような行動を取る投資家の心理を考える記述的な理論である^{1),2)}。

行動ファイナンスでは人間の認知バイアスをいくつかの種類に分類している。行動ファイナンス理論で考慮されている心理的バイアスには係留バイアス、後知恵バイアス、代表性ヒューリスティック、可用性バイ

アス、フレーミング効果等がある。本研究では、これらのうちフレーミング効果の影響について検討する。

フレーミング効果とは、問題の示され方によって人の意思決定が変わることであり、金融市場においても様々フレーミングの例がある。株式取引におけるフレーミング効果の例として、債券と株式を比べてどちらに投資するかを考えている投資家をあげることができる。このような投資家は、変動の大きい短期の株式リターンのデータだけを見たときよりも、債券よりも魅力的な長期の株式リターンのデータを見たときに、株式に多く投資することが報告されている。

本研究では、人工市場をマルチエージェントシステムとして構築し、金融市場における投資家にみられるフレーミング効果の影響について検討する。まず、Radial Basis Function(RBF) ニューラルネットワークを用いて株価を予測するエージェントを定義する。そして、実際の株価から求めたの異なる期間の移動平均曲線を用いて、エージェントに株価予想を学習させる。短期間と長期間の移動平均曲線により学習したエージェントの割合を変更した複数の人工市場におい

† 名古屋大学情報科学研究科
Graduate School of Information Sciences, Nagoya University

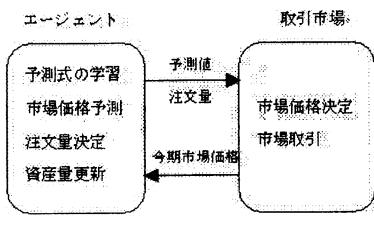


図 1 人工市場モデル
Fig. 1 Artificial market model

てシミュレーションを行い、市場価格の変動に与える影響を分析する。

2. 人工市場モデル

2.1 人工市場モデル

本研究で構築した人工市場は図 1 に示されるように複数のエージェント（エージェント集団）と取引市場から構築される。エージェントはニューラルネットワークで定義された予測式を持ち、実際の株価データから株価の予測方式を学習する。学習後は、以下のプロセスを繰り返して、市場形成を行う。

(1) 市場価格予測

(2) 注文量の決定

(3) 保有資産量の更新

取引市場では、市場価格生成とエージェント取引を行う。市場価格の形成には板寄せ方式を用いる。

2.2 エージェントの定義

従来の人工市場モデルでは、エージェントの予測式などを定義するために単純な線形関数を用いる場合が多い。このような線形関数を用いる手法では人間の複雑な心理と行動などを表現し難い場合が予想される。そこで、本研究では RBF(Radial Basis Function) ニューラルネットワークを用いてエージェントを定義する。

2.3 エージェントの予測方式形成と市場価格予測

エージェントの株価予測式は RBF ニューラルネットワークによって定義され、入力データとして過去市場価格の移動平均値 MA をとり、出力データとして次時点の市場価格の予測値 \bar{P}_t を取る。教師信号 y_t には実際の市場価格を取る。

2.4 エージェントの注文決定

エージェントは自分で予想した市場価格 \bar{P}_t を用いて、売買戦略を決定する。エージェントは、予想市場価格からリスク資産が上昇すると予想すれば買い、下降すると予想すれば売る。このときの注文量は、以下のようにして決定する。

- (1) $\bar{P}_t > P_{t-1}$ (リスク資産が上昇すると予想される) 場合は、買い注文量 O_t を次式から求める。

$$O_t = (M_t / \bar{P}_t) \times \frac{\bar{P}_t - P_{t-1}}{P_{t-1}} \times \alpha \quad (1)$$

- (2) $\bar{P}_t < P_{t-1}$ (リスク資産が下降すると予想される) 場合は、売り注文量 O_t を次式から求める。

$$O_t = S_t \times \frac{P_{t-1} - \bar{P}_t}{P_{t-1}} \times \alpha \quad (2)$$

ここで、 \bar{P}_t は、 t 期の市場価格の予測値、 P_t は t 期の市場価格、 M_t は t 期でエージェントが保有している無リスク資産量、 S_t は t 期でエージェントが保有しているリスク資産量を示す。また、 α は係数である。

2.5 エージェントの資産量更新と予測方式更新

買い手の場合新しい持つ資産量は次式から求める。

$$S'_t = S_t + O_t^* \quad (3)$$

$$M'_t = M_t - P_t \times O_t^* \quad (4)$$

売り手の場合新しい持つ資産量は次式から求める。

$$S'_t = S_t - O_t^* \quad (5)$$

$$M'_t = M_t + P_t \times O_t^* \quad (6)$$

ここで、 P_t は t 期の市場価格、 O_t^* は成立したリスク資産の取引量、 M_t は t 期で取引前にエージェントが保有している無リスク資産量、 S_t は t 期で取引前にエージェントが保有しているリスク資産量、 M'_t は t 期で取引後にエージェントが保有している無リスク資産量、 S'_t は t 期で取引後にエージェントが保有しているリスク資産量を示す。

2.6 取引市場

市場は各エージェントの買い注文量と売り注文量を受け取り、板寄せ方式で今期の市場価格を決定する。

板寄せ方式では、市場参加者全体の注文をすべて集めて、一番安い売り注文と一番高い買い注文を優先的に売買成立させていく³⁾。この時、市場全体の均衡価格は残った売り注文の価格が残った買い注文の価格より高くなる直前の価格であり、売買成立した全ての注文はこの価格で取引される。

決定された市場価格を各エージェントに知らせて、各エージェント間で取引を行う。取引成立したエージェント間では、リスク資産と無リスク資産を相互に譲渡する。

2.7 シミュレーションの流れ

- (1) エージェントと市場を初期化する。
(2) 各エージェントは RBF ニューラルネットワー

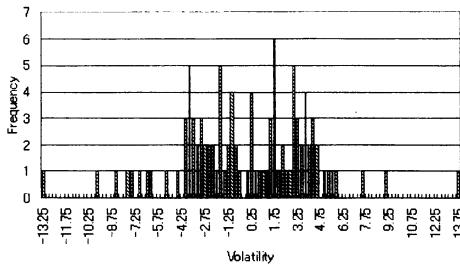


図 2 市場 1 の株価変動率の頻度分布

Fig. 2 Frequency distribution of Stock price volatility in Market 1

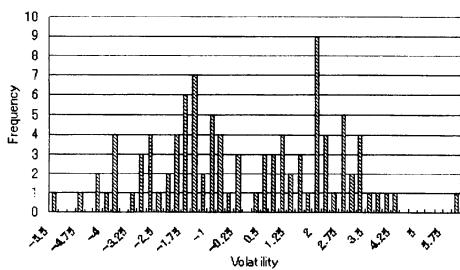


図 3 市場 2 の株価変動率の頻度分布

Fig. 3 Frequency distribution of Stock price volatility in Market 2

クによって定義された予測方法を学習する。

- (3) エージェントが学習した株価の予測方法を用いて次時点の株価を予測する。
- (4) エージェントは予測した市場価格によって、売買戦略と注文量を決める。
- (5) 市場は各エージェントの注文を受け取って、板寄せ方式で今期の市場価格を生成する。
- (6) 市場は生成した今期の市場価格をエージェントたちに知らせて、取引成立したエージェントの資産量を更新する。
- (7) 現在の市場 TimeStep 数は再学習時点と等しいなら、(2) を実行する。
- (8) 現在の市場 TimeStep 数と設定したシミュレーション Step 数を比較する。TimeStep < Step なら (3) に戻ってシミュレーションを続ける。TimeStep ≥ Step なら、シミュレーションを結束する。

3. 実験と検討

短期間(5日)と長期間(30日)の移動平均曲線により学習したエージェントの割合を変更した複数の人工市場においてシミュレーションを行い、市場価格の変

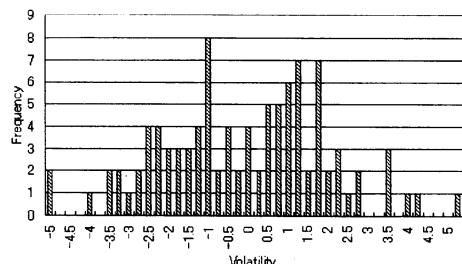


図 4 市場 3 の株価変動率の頻度分布

Fig. 4 Frequency distribution of Stock price volatility in Market 3

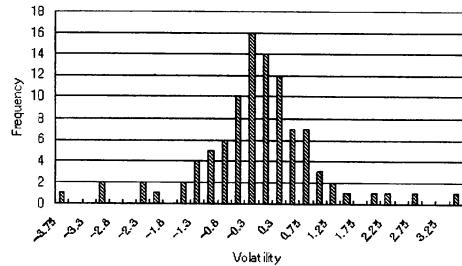


図 5 市場 4 の株価変動率の頻度分布

Fig. 5 Frequency distribution of Stock price volatility in Market 4

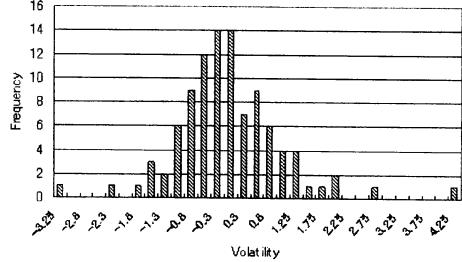


図 6 市場 5 の株価変動率の頻度分布

Fig. 6 Frequency distribution of Stock price volatility in Market 5

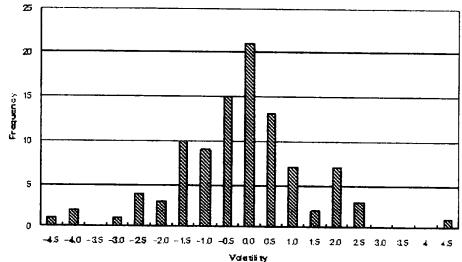


図 7 IBM の株価変動率の頻度分布 (2003 年 10 月 - 2004 年 2 月間)

Fig. 7 Frequency distribution of IBM Stock price volatility (2003 Oct. - 2004 Feb.)

動に与える影響を分析する。

エージェント数は 100 個で、エージェントの種類は 5 日と 30 日移動平均によって学習した 2 種類のエージェントとする。資産は、無リスク資産（金）とリスク資産（株）の 2 種類とする。エージェントの初期保有資産量は無リスク資産 10000、リスク資産 1000000 とする。取引期間は 100 日間、再学習時点 : $30 \times n$ ($n = 1, 2, 3, \dots$) である。なお、エージェントは原則的に無限に貸借が可能とする。

このように定義した人工市場において、エージェント 1 (5 日移動平均によって学習したエージェント) とエージェント 2 (30 日移動平均によって学習したエージェント) 2 種類のエージェントの割合が異なる次の五つの市場を考えて、株取引を行わせる。

市場 1 すべてがエージェント 1 の市場

市場 2 エージェント 1 が 75%、エージェント 2 が 25% の市場

市場 3 エージェント 1 と 2 がそれぞれ 50% の市場

市場 4 エージェント 1 が 25%、エージェント 2 が 75% の市場

市場 5 すべてがエージェント 2 の市場

構築した人工市場と実際の株式市場を比較するために株価変動率という指標を用いる。本研究では株価変動率を次式により定義する。

$$\text{株価変動率} = \frac{\text{当日の終値} - \text{前日の終値}}{\text{前日の終値} \times 100} \quad (7)$$

現実株式市場株価変動率の統計分析によって株価変動率の分布は正規分布と比べて、正規分布よりも中央が鋭くて、裾が広い性質を持っていることがよく知られている^{4), 5)}。

ここで、本研究で構築した人工市場の株価変動率の分布を調査し、実際の株式市場の特徴と比較して、構築した人工市場を評価する。

図 2 から図 6 は市場 1 から市場 5 の株価変動率の分布である。横軸は株価の変動率、縦軸は度数を示す。実際の株式市場の株価変動率と比較するために、IBM の 2003 年 10 月から 2004 年 2 月までの 100 日間株価データについての株価変動率の分布を図 7 に示す。市場 1 から市場 5 までの株価変動率の分布と図 7 を比べると、図 5 と図 6 に示す市場 4 と市場 5 (5 日移動平均によって学習するエージェントと 30 日移動平均によって学習するエージェントの割合が 25 : 75 と 0 : 100 の場合) における株価変動率の分布は実際の株式市場の株価変動率分布の特徴を表現しているので、市場 4 と市場 5 が現実の株式市場に近い変動を表現していると思われる。

4. まとめ

本研究では、行動ファイナンスで考慮される認知的バイアスの中からフレーミング効果を取り上げた。

Radial Basis Function(RBF) ニューラルネットワークを用いて株価を予測するエージェントを定義した。そして、実際の株価データから求めたの短期間と長期間の移動平均曲線を用いて、エージェントに株価予測方式を学習させた。短期間と長期間の移動平均曲線により学習したエージェントの割合を変更して複数の市場を形成した。それらの市場価格変動の分析によって、短期的なデータによって学習したエージェントが多いほど、市場の株価の変動が大きいことがわかった。そして、形成された複数の人工市場において、市場価格変動率の分布と実際の株式市場市場価格変動率の分布を比較し、長期間移動平均によって学習するエージェントが多いほど、形成された人工市場が実際の市場に近いことがわかった。

謝辞

本研究を遂行するにあたり、21 世紀 COE プログラム「計算科学フロンティア」から援助を頂いた。ここに記して謝意を表する。

参考文献

- 1) J. Goldberg and R. von Nitzsch. *Behavioral Finance*. Finanz Buch Verlag GmbH, 1999.
- 2) 加藤英明. 行動ファイナンス・理論と実証. 朝倉書店, 2003.
- 3) 和泉潔. 人工市場・市場分析の複雑系アプローチ. 森北出版社, 2003.
- 4) 斎藤定. 極値理論による資産価格変動のテールリスク分析. 2004.
- 5) 岩田曉一. 経済分析のための統計的方法. 東洋経済新報社, 1983.