

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

ザイ フェイ[†] シェン カン[†]
並 河 悠 介^{††} 北 栄 輔[†]

実際の株取引では、人間行動におけるいく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、実データを用いてそのエージェントの判断がフレーミング効果を生じることを確認する。続いて、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。短期間と長期間の移動平均によって学習した2種類のエージェントの割合を変更してシミュレーションを行い、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分かった。

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

ZHAI FEI,[†] SHEN KAN,[†] 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 prediction of the agent shows that the agent behaviour follows the framing effect. 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. Artificial markets are constructed with the agents of which prediction rules are learned by short and long moving average data. In the market of many agents learned with long-run moving average data, the features of the stock price fluctuation are similar to them of the actual market.

1. 序 論

従来のファイナンス理論は効率的市場仮説に基づいている。効率的市場とは「すべての情報は、ただちに、完全に、価格形成に反映されるので、他人より優れた投資成果を継続的にあげることができない市場」と定義される。また、市場参加者はいつも合理的な行動で市場価格を決定して、市場価格の変動はランダムウォークであるとする¹⁾。

しかし、過去20年の間に伝統的ファイナンス理論に異を唱える経済理論が提出されている。その1つが

「行動ファイナンス」である。行動ファイナンスの思想は人がいつも合理的に判断することはできない、多くの場合投資家たちの行動は合理的な基準から外れていると考えている。行動ファイナンスは人間の認知心理学を基礎としていて、投資家における投資行動の意思決定を観察し、そのような行動をとる投資家の心理を考える記述的な理論である²⁾。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、フレーミング効果などがある。

本研究では、このうちからフレーミング効果を取り上げる。フレーミング効果とは、株価変動を長期的視点で見ると、短期的視点で見ると人間の意思決定が変化する心理的バイアスである。これを表現するために、プロスペクト理論で用いる価値関数を用いて明示的にモデル化する場合、長期的と短期的を明

[†] 名古屋大学大学院情報科学研究科
Graduate School of Information Sciences, Nagoya University

^{††} NTT データ株式会社
NTT Data Co.

示的に記述する必要があり、これは一般に難しい。そこで、フレーミング効果で指摘されるところの“株価データを長期的視点と短期的視点で見ると判断が異なる”ことの原因が、“短期的にみられる株価の激しい上限変動が、長期的な株価変動では目立たない”ことであるのに着目し、これを株価の移動平均線の求め方（具体的には、平均を求める区間の長短）で置き換える。

具体的には以下のようにモデル化する。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を比較し、定義したエージェントがフレーミング効果を表現できることを確認する。また、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、市場価格の変動に与える影響を分析する。

2. 研究背景

2.1 伝統的ファイナンス理論

伝統的ファイナンス理論の基本となる効率的市場仮説 (Efficient Market Hypothesis) は、Fama が 1970 年に示した³⁾。効率的市場では、新しい情報が、迅速かつ正確に価格に反映されると仮定されている。このような市場では、最新情報は合理的投資家によって即座に判断され、瞬時に株価に反映されることになる。すなわち、市場の効率性は、合理的投資家の存在する完全競争市場における均衡価格の結果であり、このような市場では、将来の市場価格を予想することはできないことになる⁴⁾。

この仮説の基礎理論から、以下に示すような市場の反応が導かれる。

- 投資家は合理的だから、金融資産を合理的に評価する。
- 非合理的投資家が多少いても、その人たちの取引がランダムならば、その効果が互いに相殺されるので、市場価格は非合理性の影響を受けず合理的に決定される。
- 投資家の非合理性が同じ傾向を持っていても、市場では合理的な裁定取引を行う人たちの力によって非合理的な取引の影響は取り除かれる。




図 1 効用関数

Fig. 1 Utility function.




図 2 価値関数

Fig. 2 Value function.

効率的市場仮説では、合理的な人間の意思決定プロセスは以下のように考えられている。

- (1) 代替案を列挙する。
- (2) 各代替案のもたらす結果を予想する。
- (3) 結果の好ましさを評価する。
- (4) 結果の予想と好ましさを統合する。
- (5) 最適案を選択する。

合理的な人間の判断は、同じ問題では異なる状況でも好ましさの順位が変わらないとする。そして、合理的な意思決定とは効用関数における期待効用最大化を前提としている。ここで、効用関数とは財の消費量と、その財の消費によって得られる家計の満足度である効用との関係を示す。効用関数の例を図 1 に示す。

2.2 行動ファイナンス

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 (Behavioral Finance) 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、そのような行動をとる投資家の心

理を考える記述的な理論である^{5),6)}。

行動ファイナンスの1つに、プロスペクト理論がある。プロスペクト理論は人間の意思決定は効用関数ではなく、価値関数に従うことを示している。価値関数とは、望ましさの心理学的評価値（標準理論の効用関数に相当）で、たとえば図2のような形をしている⁷⁾。横軸は利益と損失を、縦軸は価値を示し、中心点は儲けと損失の分岐点となる参照基準点（reference point）である⁸⁾。プロスペクト理論の価値関数では、金銭の期待値でもなく、金銭から得られる効用の期待値でもなく、金銭から得られる、価値の期待値によって選択を判断することとなる。この価値の概念は、効用と非常に近い概念であるが、人間の非合理性を反映しているところが異なっている。

プロスペクト理論では人間の意思決定に対して、「利得発生時と損失発生時において投資家のリスクに対する態度が異なる」こと、「人間の意思決定は客観確率ではなく主観確率により行われる」などの特徴があることを示唆している⁸⁾⁻¹⁰⁾。

2.3 認知バイアス

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。つまり、係留点バイアス、後知恵バイアス、代表性ヒューリスティクス、可用性バイアス、フレーミング効果などである⁷⁾。

- (1) 係留バイアス（anchoring adjustment）
すでに利用できる情報を参照点として、推測値をそのまわりに係留させるバイアスである。
- (2) 後知恵バイアス（hindsight bias）
予測した当時は不確実だった事柄を、起こってから必然的に起きたように感じたり、あたかも予測していたかのように解釈したり、振る舞ったりすることを後知恵バイアスと呼ぶ。
- (3) 代表性ヒューリスティック（representativeness heuristics）
人は、あるリスク事象の確率を直観的に判断するときに、限られた事例（標本）を用いて、事象全体の確率を判断する。そのときに、ある事例が、そのリスク事象（母集団やカテゴリ）を代表していると認知できるほど、生起確率を高く判断する。
- (4) 可用性バイアス（availability bias）
ある事象の発生可能性についての判断は、その事象についてのイメージを作るための情報が入手しやすいかどうか影響される。
- (5) フレーミング効果（framing effect）
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る。

2.4 フレーミング効果

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、金融価格の変動を長期的に見て判断する場合と短期的に見て判断する場合で投資家が異なる判断を示すことである¹¹⁾。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。債券と比べて、株式の価格変動は短い期間で大きな上下変動をみせる一方で、長く保有すれば高い利得を得ることができることがある。このような株価の価格変動を提示する場合に、短期リターンデータだけを見ると投資家は株式よりも債券を購入するのに対して、長期リターンデータを見ると、株式に多く投資することが報告されている^{2),10)}。

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、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を比較し、定義したエージェントがフレーミング効果を表現できることを確認する。最後に、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とエージェントの行動を分析する。

3. 人工市場モデル

3.1 人工市場モデル

本研究で構築した人工市場は図3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株価予測式を持ち、実際の株価データから株価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




図3 人工市場モデル

Fig. 3 Artificial market model.




図4 RBFニューラルネットワーク
Fig.4 RBF neural network.

(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。

3.2 エージェントの定義

エージェントはRBFニューラルネットワークで定義された株価予測式を持ち、実際の株価データから株価の予測式を学習する。そして、予測した株価に基づき後述するアルゴリズムに従って株式の売買と注文量を自律的に決定し、市場取引を行う。

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ニューラルネットワークを用いて予測式を定義する。

3.2.1 RBFニューラルネットワーク

本研究で用いるRBFニューラルネットワークは図4に表現されるように、複数の入力層と1つの出力層の間に中間層を配置した三層構造のネットワークである。

出力層の関数 $F(x)$ は、中間層の基底関数 $\Phi_i(x)$ の線形結合として式(1)のように定義する^{12),13)}。

$$F(x) = \sum_{i=1}^n \omega_i \Phi_i(x) \quad (1)$$

中間層の基底関数 $\Phi_i(x)$ には式(2)で示されるガウス関数を用いる。

$$\Phi_i(x) = \exp\left(-\frac{(x - c_i)^2}{\sigma_i^2}\right) \quad (2)$$

ここで、 $\Phi_i(x)$ 、 c_i 、 σ_i はそれぞれ i 番目中間層ユニットの出力、中心、正規化パラメータである。 ω_i は中間層と出力層の重み係数である。

このモデルでは、入力データが中間層の基底関数に近づくほど、基底関数は大きな出力を出し、遠ざかるほど小さな出力を出すので、実際に脳が行っているバ

ターン認識における心理量を近似しているため心理学的にも適切なモデルを定義できると考えられる¹⁴⁾。

3.2.2 学習アルゴリズム

RBFニューラルネットワークには3つのパラメータがある。中間層基底関数の配置位置を決めるための中心 c_i 、基底関数領域を表示する正規化パラメータ σ_i と中間層と出力層間の結合強度を示す重み ω_i である。

RBFニューラルネットワークを学習するために、まず、中間層基底関数の中心 c_i と正規化パラメータ σ_i を決定する。この中心と正規化パラメータは基底関数のパラメータであるため、この2つのパラメータを決定することはRBFニューラルネットワークの構造を決定することを意味する。

中心 c_i の決定は k -means クラスタリング法を用いる。また、正規化パラメータの決定には k -近傍法を用いる。中間層と出力層の重み ω_i は誤差逆伝播法によって決定する。

3.2.2.1 k -means クラスタリング法

k -means クラスタリング法は N 個のデータ x_i ($i = 1 \dots n$) をある評価基準に従って、 k 個のクラスター G_i ($i = 1 \dots k$) に分類する手法である^{12),13)}。 k -means クラスタリング法のアルゴリズムは以下のようになる。

Step1 すべてのデータをランダムに k 個のクラスターに分けて、各クラスターの中心 c_i をランダムに決める。

Step2 すべてのデータと各クラスターの中心 c_i とのユークリッド距離を式(3)によって計算し、式(4)の条件を満たすときデータ x_i をクラスター G_i に属させる。

$$D(x, c) = \left(\sum_{k=1}^T (x_k - c_k)^2 \right)^{\frac{1}{2}} \quad (3)$$

$$D(x_i, c_j) < D(x_i, c_l) \quad j \neq l \quad (4)$$

Step3 式(5)に従って、クラスターの中心 c_i を更新する。

$$c_i = \frac{1}{|G_i|} \sum_{x_j \in G_i} x_j \quad (5)$$

ここで $|G_i|$ はクラスター G_i に属するデータの総数である。

Step4 すべてのクラスターについて求めた新しい中心 c_j が前回の中心と等しくなったとき、アルゴリズムを終了する。それ以外なら Step2 へ戻る。

3.2.2.2 k -近傍法

k -近傍法は入力空間における中間層基底関数どうし




図5 誤差逆伝播法

Fig.5 Back propagation.

の影響の重複を調整するために、正規化パラメータ σ_i を変化させる手法である^{12),13)}。

i 番目中間層基底関数の正規化パラメータ σ_i はその基底関数の中心 c_i から近傍の k 個の中間層基底関数中心までの距離の平均によって計算する。

$$\sigma_i = \frac{1}{k} \sum_{j=1}^k |c_i - c_j| \quad (6)$$

ここで、 c_j ($j = 1 \dots k$) は中心 c_i に最も近い k 個の基底関数の中心である。また、 k は実験的に決定する。

3.2.3 誤差逆伝播法

誤差逆伝播法を説明するために図5を考える。ここで、横軸は重み ω_i 、縦軸は二乗誤差 E を示す。 E は式(7)で定義される。 y_i と $o_i(\omega_i)$ はそれぞれ教師信号と出力値を表す。 E が最小になるような重みを $\bar{\omega}_i$ とし、今の重みを $(\omega_i)_{old}$ とする。学習によって $(\omega_i)_{old}$ から $\bar{\omega}_i$ へ近づくように重みの更新をするため、 $(\omega_i)_{old}$ の傾きから変更量 $\Delta\omega_i$ を求め、式(8)によって新しい重み $(\omega_i)_{new}$ を求める¹³⁾。

$$E = \frac{1}{2} \sum_i (y_i - o_i(\omega_i))^2 \quad (7)$$

$$(\omega_i)_{new} = (\omega_i)_{old} + \Delta\omega_i \quad (8)$$

$(\omega_i)_{old}$ の傾きは偏微分 $\frac{\partial E}{\partial \omega_i}$ で表すことができる。係数 η を付用いて変更量 $\Delta\omega_i$ は式(9)で定義する。

$$\Delta\omega_i = -\eta \frac{\partial E}{\partial \omega_i} \quad (9)$$

ここで、係数 η は学習率と呼ばれる正の定数である。この学習率が大きく設定すると学習速度が上がるが、学習効果が振動する。逆に学習率が小さく設定すると、学習効果が安定するが、学習速度が遅くなる。本研究は実験的な手法で学習率係数 η を決定する。

3.3 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 をとる。教師信号 y_i に

は実際の市場価格をとる。

ここで、移動平均値 (Moving Average) MA は最も基本的なテクニカル指標で、アメリカの著名なチャートストの J.E. グランビルの投資法則によって急速に普及した¹⁵⁾。 t 期の株価を P_t とすると、過去 n 期の株価の移動平均値は次式で定義される。

$$MA = \frac{P_0 + P_1 + \dots + P_{n-1}}{n} \quad (10)$$

3.4 エージェントの注文決定

各エージェントは自分が予測した市場価格をもとに、リスク資産または無リスク資産をどれくらい売買するかという投資戦略を決定して、市場取引に参加する。

本研究では、市場にはリスク資産(株)と無リスク資産(金)の2種類の資産が存在すると仮定する。エージェントの初期保有資産量は無リスク資産 1,000,000、リスク資産 10,000 とする。

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。

$$O_t = (M_t / \bar{P}_t) \times \frac{\bar{P}_t - P_{t-1}}{P_{t-1}} \times \alpha \quad (11)$$

(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。

$$O_t = S_t \times \frac{P_{t-1} - \bar{P}_t}{P_{t-1}} \times \alpha \quad (12)$$

ここで、各パラメータは以下のことを示す。

\bar{P}_t t 期の市場価格の予測値

P_t t 期の市場価格

M_t 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 t 期でエージェントが保有しているリスク資産量

α 係数

3.5 エージェントの資産量更新と予測方式更新

各エージェントは自分が予測した市場価格と決定した注文量を用いて、市場取引に参加する。市場で取引成立したエージェントが成立した取引量と決定された今期市場価格によって、下記の式のように自分の有する資産量を更新する。

買い手の場合新しい持つ資産量は次式から求める。

$$S'_t = S_t + O_t^* \quad (13)$$

$$M'_t = M_t - P_t \times O_t^* \quad (14)$$

売り手の場合新しい持つ資産量は次式から求める．

$$S'_t = S_t - O_t^* \quad (15)$$

$$M'_t = M_t + P_t \times O_t^* \quad (16)$$

ここで、各パラメータは以下のことを示す．

P_t t 期の市場価格

O_t^* 成立したリスク資産の取引量

M_t 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 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 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 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

ここで、 O_t^* については少し説明が必要である．エージェントの売買注文量は独立して定まるわけではない．次節で述べるように市場は、エージェントからの売買注文を受け、板寄せ方式で順次売買注文を成立させていく．その結果として市場価格が決定してから、はじめて成立したエージェント間で取引が行われる． O_t^* とは、価格決定後に市場で成立した取引量を指している．つまり、 O_t^* はエージェントが最初に発注した取引量とは必ずしも一致しない．

また、ある期間の市場取引が行われた後に、各エージェントは自分の予想と人工市場生成した市場価格との違いを認識する．そして、より正確な予想方式形成のために、新しい市場価格の履歴値を用いて、自分の予測方式（RBF ニューラルネットワークの構造）を修正し、次の取引期間に向けて新しい予測方式を形成する．

3.6 取引市場

3.6.1 市場価格の形成

各エージェントの買い注文量と売り注文量は市場に集められ、板寄せ方式によって今期の市場価格が決定される．

板寄せ方式は、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き、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まで次々に成立させていく方式である¹⁶⁾．このとき、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、売買成立したすべての注文はこの価格で取引される．

3.6.2 市場取引

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．

なお、板寄せ方式に従うので、前節で決定された今期の市場価格より高い予測価格を持っていた買い手エージェントと市場価格より安い予測価格を持っていた売り手エージェント、またより低い予測価格を持っていた買い手エージェントと市場価格より高い予測価格を持っていた売り手エージェントの間では市場取引は行われない．また、取引を実行できなかった他のエージェントの資産は以前の資産保有量のままである^{16),17)}．

3.7 シミュレーションの流れ

各エージェントは、RBF ニューラルネットワークによって定義された予測式を一定期間ごとに再学習する．シミュレーションタイムステップを t 、最大シミュレーション回数を t_{\max} とする．また、再学習を行う頻度を t_{rel} とする．つまり、 t_{rel} タイムステップごとに再学習を行うものとする．以下のシミュレーションにおいては、 $t_{rel} = 30$ としている．

- (1) エージェント数と割合、エージェントの初期保有資産量などを入力する．
- (2) エージェントと市場を初期化する．具体的には、RBF ニューラルネットワークの中間層の中心座標、正規化パラメータ、中間層と出力層の重み係数をランダムに決定する．
- (3) タイムステップ t を初期化する．つまり、 $t \leftarrow 0$ ．
- (4) 各エージェントは、RBF ニューラルネットワークによって定義された予測方法を学習する．
- (5) エージェントは、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．
- (6) 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定める．
- (7) 各エージェントの注文を市場に集め、板寄せ方式で今期の市場価格を決定する．
- (8) 取引成立したエージェントの資産量を更新する．
- (9) $t \leftarrow t + 1$
- (10) $Mod(t, t_{rel}) = 0$ ならば、(4) へ戻る．ここで $Mod(t, t_{rel})$ は t を t_{rel} で除算した余りを示す．
- (11) $t < t_{\max}$ ならば、(5) へ戻る．そうでなければ、シミュレーションを終了する．

4. 実験と考査

4.1 エージェント予測行動によるフレーミング効果の検証

3章で述べた 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、実際の株価から短期間と長期間の移動平均曲線を用い




図 6 上昇トレンドの株価

Fig. 6 Stock price with increasing trend.

て、株価予測方式を学習させる。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予測行動を比較し、定義したエージェントの予測行動がフレーミング効果を表現できることを示す。本研究では短期間とは 5 日の移動平均曲線を、長期間として 30 日移動平均曲線を用いる。

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を考える。エージェントの学習回数は、それぞれ 5000 回で、学習率 $\eta = 0.6$ である。なお、RBF ニューラルネットワークの入力層ニューロン数は 10 個、中間層ニューロン数は 20 個、出力層ニューロン数は 1 個である。学習データは 200 日間のものを取り、予測期間は 100 日間とする。以下では、短期間 (5 日) 移動平均値によって学習したエージェントをエージェント 1、長期間 (30 日) 移動平均値によって学習したエージェントをエージェント 2 とする。

4.1.1 上昇するトレンドの場合

学習とシミュレーションに用いる実際の株価データを図 6 に示す。図中には、5 日と 30 日の移動平均線も記載する。横軸には、ある日から数えた経過日数 (タイムステップ)、縦軸には株価をとっている。この株価データは、短期的には上下変動をとるが、長期的には上昇するトレンドを示している。

図 6 に示した連続データについて、最初の 200 日分のデータをニューラルネットワークの学習に用い、残りのデータを学習したニューラルネットワークの予測に用いる。短期間 (5 日) 移動平均曲線によって学習したエージェントと長期間 (30 日) 移動平均値によって学習したエージェントの株価予測値を図 7 と図 8 に示す。横軸には、予測開始日 (データでは 201 日目) から数えた経過日数、縦軸には株価をとっている。ラベル Real price, Agent1, Agent2 は、それぞれ株価の実際の変動、5 日移動平均と 30 日移動平均を用いて学習したエージェントによる予測値を示す。




図 7 上昇トレンドの株価においてエージェント 1 が予想した株価

Fig. 7 Prediction of Agent 1 for stock price with increasing trend.




図 8 上昇トレンドの株価においてエージェント 2 が予想した株価

Fig. 8 Prediction of Agent 2 for stock price with increasing trend.




図 9 下降トレンドの株価

Fig. 9 Stock price with decreasing trend.

これにより、5 日移動平均を用いて学習したエージェント 1 の予測値は、30 日移動平均を用いたエージェント 2 より予測値の上下変動が大きいたことが分かる。これはちょうど、実際の市場において投資家が株式の短期的な変化と長期的な変化のいずれかだけを見て判断するとき、短期的なデータでは株価変動の大きさを強く意識するというフレーミング効果を表現していると考えられる。

4.1.2 下降するトレンドの場合

学習に用いた実際の株価データを図 9 に示す。図中には、5 日と 30 日の移動平均線も記載する。上昇す




図 10 下降トレンドの株価においてエージェント 1 が予想した株価
 Fig.10 Prediction of Agent 1 for stock price with decreasing trend.

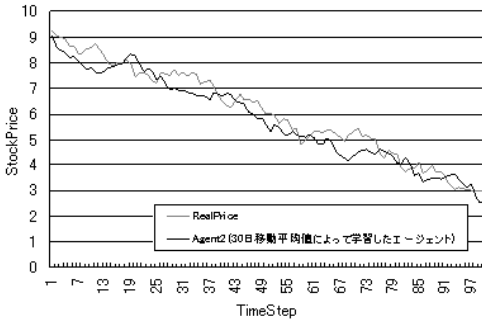


図 11 下降トレンドの株価においてエージェント 2 が予想した株価
 Fig.11 Prediction of Agent 2 for stock price with decreasing trend.

るトレンドの場合と同じようにこの株価データは、短期的には上下変動をとまなうが、長期的には下降するトレンドを示している。上昇するトレンドの場合と同じ条件でシミュレーションし、短期間（5 日）移動平均値によって学習したエージェントと長期間（30 日）移動平均値によって学習したエージェントの株価予測値をそれぞれ図 10 と図 11 に示す。この場合についても、5 日移動平均を用いて学習したエージェント 1 の予測値は、30 日移動平均を用いたエージェント 2 より予測値の上下変動が大きく、フレーミング効果を表現していると考えられる。

4.2 株価の創発

図 6 に示した株価データの最初 200 日分のデータから短期間（5 日）と長期間（30 日）の移動平均曲線を作成し、それらにより学習した 2 種類のエージェントを用意する。そして、それらの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 10,000、リスク資産 1,000,000 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。無限に貸借可能という仮定は実際の市場取引とは異なるが、本研究の目的はフレーミング効果の株取引への影響評価なので、この目的については上記の仮定による影響は少ないと考えられる。

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）の 2 種類のエージェントの割合が異なる次の 5 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

4.2.1 株価予測の精度

5 つの市場について、エージェントが予測する株価が実際の市場価格とどれほど異なるかについて検討する。各市場において、全エージェントについて予測株価と実際に市場取引で決定された株価の誤差を計算する。続いて、エージェント 1 または 2 ごとに、誤差の平均値を求めることにする。

評価結果を図 12，図 13，図 14，図 15，図 16 に示す。横軸にはタイムステップを縦軸にはエージェントの種類ごとに求めた予想値と実際の株価の誤差の平均値を示す。曲線は、エージェント 1 と 2 の結果を示す。ただし、市場 1 と 5 は、それぞれエージェント 1 または 2 だけからなる市場なので、存在するエージェントについてのみ示している。また、各タイムステップでの誤差平均値を時間について平均した値を表 1 に示す。

これらの結果より、1 つのエージェントしか存在しない市場 1 と 5 の誤差平均値が他市場に比べて小さく、表 1 から分かるように、それらの全タイムステップについて求めた平均はほぼ同じ程度である。また、全市場のうち市場 3 の誤差平均値が最も大きいことが分かる。

このことより、エージェントが 1 種類であれば、エージェントの予測値は市場価格をある程度精度良く予測するのに対して、異なるエージェントが存在し、一方




図 12 市場 1 における予測株価精度

Fig. 12 Accuracy of predicted stock price in Market 1.




図 16 市場 5 における予測株価精度

Fig. 16 Accuracy of predicted stock price in Market 5.




図 13 市場 2 における予測株価精度

Fig. 13 Accuracy of predicted stock price in Market 2.




図 14 市場 3 における予測株価精度

Fig. 14 Accuracy of predicted stock price in Market 3.




図 15 市場 4 における予測株価精度

Fig. 15 Accuracy of predicted stock price in Market 4.

表 1 株価予測精度の平均
Table 1 Average value of accuracy of predicted stock price.

| Market | Agent 1 | Agent 2 |
|--------|---------|---------|
| 1 | 0.069 | - |
| 2 | 0.217 | 0.078 |
| 3 | 0.190 | 0.141 |
| 4 | 0.190 | 0.077 |
| 5 | - | 0.065 |




図 17 市場 1 の取引高

Fig. 17 Volume of dealing in Market 1.




図 18 市場 2 の取引高

Fig. 18 Volume of dealing in Market 2.

のエージェントの他方のエージェントに対する割合が 1 に近づくほど、市場価格の変化がエージェントの予測から離れていくことを示している。

4.2.2 取引成立高

5 つの市場における取引成立高の時間変化を図 17、

図 18、図 19、図 20、図 21 に示す。横軸にはタイムステップを縦軸には取引高（回数）を示す。すべての図において取引高の時間変化を 2 次関数で最小二乗近似した曲線も同時に記載している。これを見ると、どの市場においても初期が最も取引成立高が大きく、その後徐々に減少していることが分かる。また、市場




図 19 市場 3 の取引高

Fig. 19 Volume of dealing in Market 3.




図 20 市場 4 の取引高

Fig. 20 Volume of dealing in Market 4.




図 21 市場 5 の取引高

Fig. 21 Volume of dealing in Market 5.

1 においては取引成立高の推移は比較的直線的に減少しているのに対して、その他の市場では 50~60 タイムステップあたりまで減少して、その後増加に転じているようにも見受けられる。

4.2.3 株価変化率

5 つの市場の市場株価と市場株価の変化率を図 22、図 23、図 24、図 25、図 26 に示す。ここで、株価変化率は次式で定義される。

$$\begin{aligned} & \text{株価変化率} \\ &= \frac{\text{当日の終値} - \text{前日の終値}}{\text{前日の終値}} \times 100 (\%) \end{aligned} \tag{17}$$

グラフから、市場 1 が最も市場価格の変動幅が大き




図 22 市場 1 の株価と株価変化率

Fig. 22 Stock price and its volatility in Market 1.




図 23 市場 2 の株価と株価変化率

Fig. 23 Stock price and its volatility in Market 2.




図 24 市場 3 の株価と株価変化率

Fig. 24 Stock price and its volatility in Market 3.

く、市場 5 が最も小さいことが分かる。市場 1 から市場 5 に向けて、エージェント総数におけるエージェント 1 の個体数は減少している。このことより、短期的な変動に影響を受けるエージェント 1 の個体数が大きいほど、市場価格の変動が大きくなると考えられる。実際の市場においては、非常に短い周期で株の売買を繰り返して利益を確定しながらもうける個人の投資家がみられる。エージェント 1 は、そのような投資家を表現しているといえる。これに対して、エージェント 2 は、エージェント 1 に比べて長期的な変動によって学習しているので、エージェント 1 に比べて株価の短期的な変動にあまり影響されない。その結果として




図 25 市場 4 の株価と株価変化率

Fig. 25 Stock price and its volatility in Market 4.




図 26 市場 5 の株価と株価変化率

Fig. 26 Stock price and its volatility in Market 5.

エージェント 2 の個体数が多いほど、市場価格の変動が安定状態となったと考えられる。

また、エージェント 1 の個体数が多いほど(つまり、市場 5 から市場 1 へ向けて)、株価変動の周期が小刻みになり、振幅が大きくなっている。この原因の 1 つとして、エージェントの株価予測の傾向が比較的似通っていることが考えられる。つまり、株価予測が似通っている場合、次の投資行動が似通ってしまうことが予想される。その結果、同時に売りまたは買いの行動を行うので、結果的に大きな上昇と下降を繰り返しているのではないだろうか。しかし、これについては、今後詳細な検討が必要である。

4.3 人工市場の評価

現実株式市場株価変化率の統計分析によって、株価変化率の頻度分布は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^{15),18),19)}。

ここで、本研究で構築した人工市場の株価変化率の頻度分布を調査し、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 27, 図 28, 図 29, 図 30, 図 31 は市場 1 から市場 5 の株価変化率の頻度分布である。横軸は株価の変化率、縦軸は度数を示す。実際の株式市場の株価変化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




図 27 市場 1 の株価変化率の頻度分布

Fig. 27 Frequency distribution of volatility in Market 1.




図 28 市場 2 の株価変化率の頻度分布

Fig. 28 Frequency distribution of volatility in Market 2.




図 29 市場 3 の株価変化率の頻度分布

Fig. 29 Frequency distribution of volatility in Market 3.




図 30 市場 4 の株価変化率の頻度分布

Fig. 30 Frequency distribution of volatility in Market 4.

株価変化率の分布を図 32 に示す。市場 1 から市場 5 までの株価変化率の分布と図 32 を比べると、図 30 と図 31 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)における株価変化率の分布は実際の株式市場の株価変化率分布の特徴を表現しているため、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。

市場価格における自己相関係数 (Self-corelative coefficient of Stock Price: SSP), 株価変化率における




図 31 市場 5 の株価変化率の頻度分布

Fig. 31 Frequency distribution of volatility in Market 5.




図 32 IBM の株価変化率の頻度分布 (2003 年 10 月—2004 年 2 月間)

Fig. 32 Frequency distribution of IBM Stock price volatility (2003 Oct. - 2004 Feb.).

表 2 利得に関するパラメータ
Table 2 Parameter of return.

| Parameter | Real Market |
|-----------|-------------|
| SSP | 0.05-0.10 |
| SSC | 0.40-0.60 |
| PRi1S | 0.75-0.80 |
| PRo3S | 0.01-0.02 |

表 3 各人工市場におけるパラメータ
Table 3 Parameter estimated at artificial markets.

| Parameter | Market | | | | |
|-----------|--------|-------|-------|-------|-------|
| | 1 | 2 | 3 | 4 | 5 |
| SSP | 0.60 | 0.47 | 0.35 | -0.21 | 0.02 |
| SSC | -0.09 | -0.41 | -0.43 | -0.92 | -0.91 |
| PRi1S | 0.42 | 0.67 | 0.78 | 0.75 | 0.74 |
| PRo3S | 0.017 | 0.00 | 0.01 | 0.00 | 0.00 |

自己相関係数 (Self-correlation coefficient of Stoch Change rate: SSP), 1σ 内の確率 (Probability of Return in 1 Sigma: PRi1S), 3σ 外の確率 (Probability of Return out of 3 Sigma: PRo3S) について表 2 のような特徴があることが示されている²⁰⁾。そこで、先の 5 市場についてこれらのパラメータを評価した結果を表 3 に示す。この結果を見ると、市場価格の自己相関係数 (SSP) と株価変化率の自己相関係数 (SSC) はすべての市場で実市場と一致していない。これに対して、 1σ 内の確率 (PRi1S) については市場 3, 4 が一致し、市場 5 が近い値を示している。ま

た、 3σ 外の確率 (PRo3S) については市場 4, 5 が一致し、市場 3 が近い値を示していることが分かる。このことより、30 日移動平均によって学習するエージェントが多いほど実市場に近い特徴を示しているといえるが、はずれているパラメータも多いので今後いっそうの検討が必要である。

5. 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。フレーミング効果とは、金融価格の変動を長期的に見て判断する場合と短期的に見て判断する場合で投資家が異なる判断を示すことである。

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予測行動の比較により、短期間移動平均を用いて学習したエージェントの予測値は、長期間移動平均を用いたエージェントより予測値の上下変動が大きかった。この結果は、実際の市場において投資家が市場の短期的な変化と長期的な変化のいずれかだけを見て判断するときに、短期的なデータでは価格変動の大きさを強く意識するというフレーミング効果を表現していると考えられる。


次に、定義した短期間と長期間移動平均によって学習する 2 種類のエージェントの割合を変更して、複数の市場を形成させた。複数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、市場価格変化率の分布と実際の株式市場市場価格変化率の分布を比較し、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傾向がみられた。

本研究では、構築した人工市場にリスク資産と無リスク資産の 2 種類の資産だけが取引できると想定している。構築した人工市場を複数のリスク資産が取引できるように拡張したい。また、今後他の認知的バイアスの影響などについても検討を進めていきたいと考えている。

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」から援助をいただいた。ここに記して謝意を表する。

参 考 文 献

- 1) 筒井義郎：金融，東洋経済新報社（2001）.
- 2) 加藤英明：行動ファイナンス・理論と実証，朝倉書店（2003）.
- 3) Fama, E.: Efficient capital markets: A review of theory and empirical work, *Journal of Finance*, Vol.25, pp.383-417 (1970).
- 4) Ingersoll, J.E.: *Theory of Financial Decision Making*, Rowman and Littlefield (1987).
- 5) Goldberg, J. and von Nitzsch, R.: *Behavioral Finance*, Finanz Buch Verlag GmbH (1999).
- 6) Shleifer, A.: *Inefficient Markets*, Oxford University Press (2000).
- 7) 角田康夫：行動ファイナンス・金融市場と投資家心理のパズル，社団法人金融財政事情研究会（2001）.
- 8) 東京三菱銀行資金証券部：行動ファイナンスによる相場変動の分析（2003）.
- 9) Kahneman, D. and Tversky, A.: Prospect theory: An analysis of decisions under risk, *Econometrica*, Vol.47, pp.263-291 (1979).
- 10) 岡本浩一，今野裕之，堀 洋元，大野 晋，王晋民，足立にわか，石川正純，鎌田晶子，上瀬由美子，岡部康成，下村英雄，宮本聡介：リスク・マネジメントの心理学，新曜社（2003）.
- 11) A. シュレイファー：金融パブルの経済学，東洋経済新聞社（2001）.
- 12) 坂和正敏，田中雅博：ニューロコンピューティング入門，森北出版（1997）.
- 13) 電気学会 GA ニューロを用いた学習法とその応用調査専門委員会：学習とそのアルゴリズム—ニューラルネットワーク・遺伝アルゴリズム・強化学習，森北出版（2002）.
- 14) Joo, M., Wu, S., Lu, J. and Lye, H.: Face recognition with radial basis function (rbf) neural networks, *IEEE Trans. Neural Networks*, Vol.13, No.3, pp.697-710 (2002).
- 15) 林 康史：株価が読めるチャート分析入門，かんき出版（2000）.
- 16) 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）.
- 17) 和泉 潔，植田一博：人工市場入門，情報処理学会知能と複雑系研究会，Vol.119, No.1, pp.127-134 (2000).
- 18) 齋藤 定：極値理論による資産価格変動のテールリスク分析（2004）.
- 19) 岩田暁一：経済分析のための統計的方法，東洋経済新報社（1983）.
- 20) 原 章，長尾智晴：自動グループ構成手法 ADG を用いた人工株式市場の構築，情報処理学会論文誌，Vol.43, No.7, pp.2292-2299 (2002).
(平成 17 年 8 月 23 日受付)
(平成 18 年 2 月 22 日再受付)
(平成 18 年 3 月 7 日採録)



ザイ フェイ

1978 年生．名古屋大学大学院情報科学研究科博士課程後期課程在学中．マルチエージェントシミュレーションを用いた人工市場モデル，特に行動ファイナンス理論に関する研究に従事．



シェン カン

1977 年生．名古屋大学大学院情報科学研究科博士課程後期課程在学中．進化的計算手法と自己組織化マップに関する基礎的研究，および，金融・経済問題への応用研究に従事．



並河 悠介

1980 年生．名古屋大学大学院情報科学研究科博士課程前期課程修了．現在，NTT データ（株）勤務．マルチエージェントシミュレーションを用いた，経済物理学，行動ファイナンスに関する研究に従事．



北 栄輔（正会員）

1964 年生．1991 年名古屋大学大学院工学研究科博士課程後期課程修了．博士（工学）．1999 年より名古屋大学助教授，現在に至る．数値解析法（BEM，Trefftz 法），セル・オートマトン（Cellular Automata）等の研究に従事．著書に，『偏微分方程式の数値解法』，『計算のための線形代数』，『Trefftz 法入門』等．IEEE，ISBE，応用数理学会，日本機械学会，シミュレーション学会，日本計算工学会各会員．