

遺伝的アルゴリズムモデルによる投資家心理の記述とその条件

山田 隆志[†] 植田 一博^{††}

† 東京大学大学院総合文化研究科広域科学専攻広域システム科学系 〒153-8902 東京都目黒区駒場3-8-1

†† 東京大学大学院情報学環 〒113-8654 東京都文京区本郷7-3-1

E-mail: †tyamada@blake.c.u-tokyo.ac.jp, ††ueda@gregorio.c.u-tokyo.ac.jp

あらまし 本論文の目的は、定式化された行動ファイナンスの一つである投資家心理のモデル (Barberis et al., J. of Financial Economics, 49, pp.307-343, 1998) が、複雑系経済学モデルでよく用いられる遺伝的アルゴリズムの学習を用いて記述できるかを検証することである。そのために、遺伝的アルゴリズムに関する様々なパラメータの組合せについて、典型的な価格列をエージェントに与え、エージェントの市場に対する見方の推移から、投資家心理モデルが再現できるための条件を探った。その結果、投資家心理モデルを記述するためには主に以下の二条件を満たす必要があった。まず、適合度計算にあたってエージェントには市場の状態を教えないなければならないことであり、もう一つは、学習において親の選択には最新の情報を用いなければならないことである。

キーワード 複雑系経済学モデル、遺伝的アルゴリズム、学習、投資家心理

Conditions for Genetic Algorithm Learning Describes Investor Sentiment

Takashi YAMADA[†] and Kazuhiro UEDA^{††}

† Department of General Systems Studies, Graduate School of Arts and Sciences, University of Tokyo
3-8-1 Komaba, Meguro-ku, Tokyo, 153-8902 Japan

†† Interfaculty Initiative of Information Studies, University of Tokyo
7-3-1 Hongo, Bunkyo-ku, Tokyo, 113-8654 Japan

E-mail: †tyamada@blake.c.u-tokyo.ac.jp, ††ueda@gregorio.c.u-tokyo.ac.jp

Abstract The purpose of this paper is to clarify whether the Genetic Algorithm Learning can describe the Model of Investor Sentiment (Barberis et al., J. of Financial Economics, 49, pp.307-343, 1998), one of the studies of the Behavioral Finance. For this purpose, we explored the conditions using the agents' viewpoints towards market which were obtained when some series of typical asset-returns were given. As a result, some conditions for genetic algorithm were shown to be required: First, in order to represent the model of investor sentiment by genetic algorithm learning, agents need to know market condition for their learning. Second, the information used when agents select their parents must be up-to-date.

Key words agent-based computational economics, genetic algorithm, learning, investor sentiment

1. まえがき

遺伝的アルゴリズム (GAs) は、複雑系経済学モデルを構築する際のエージェントの学習手法として広く採用されていて、具体的には、多様性の生成とその制限という二種類の確率過程で構成されている (Riechmann [13])。確かに、GAs を用いた場合、シミュレーション結果から理論的な結論を導くことは難しいが、エージェントはかなり広範な探索を行うことが出来る (LeBaron [9])。さらに Arifovic and Gencay は、GAs を用いる利点として、コンピュータの能力をそれほど必要としない、エージェントの信念の異質性を表現できる、決定ルールの生存

はそのパフォーマンスに依存する、を挙げている [1]。

しかし、これまでの複雑系経済学モデルへの GAs の適用は、投資行動の選択 (Lawrenz and Westerhoff [8], Routledge [14])、入力情報への対応 (Arthur ら [2], Izumi and Ueda [7])、ポートフォリオ選択 (Arifovic and Gencay [1], Lettau [10]) などに限られており、市場参加者による価格変動やリスクへの態度を扱った行動経済学の知見を GAs で記述する試みはあまり見られない。そこで筆者らは、価格変動への投資家の態度を定式化した Barberis らのモデル (A Model of Investor Sentiment: MIS) [3] が遺伝的アルゴリズムの学習 (Genetic Algorithm Learning: GAL) を用いて表現できるかどうかを検証した。

本論文は以下のような構成になっている。第2章では、Barberisらの投資家心理のモデルの概要を紹介する。次に、第3章でGALモデルを説明し、それがMISを記述できるのかを第4章で検証する。第5章で結論としている。

2. 投資家心理モデルの概略

Barberisらは、Tversky and Kahneman[15]が提唱した「保有主義」と「代表性ヒューリスティック」を説明するために、式(1)、(2)で表されるモデルを設定した(図1、表1)。つまり、二種類の状態——安定な状態と不安定な状態(図1)——が存在する市場と一種類の資産がある。この資産に関して、毎期+1あるいは-1のリターンが投資家に与えられる。このリターンの与えられ方は表1の通りで、これは投資家にも知られている。投資家はこのリターンをもとに、市場の状態を推測する。市場が不安定であると投資家が認識する確率を q_t としたとき、二期続けてリターンが同じであるときは認識確率が式(1)で更新されるのに対し、リターンが異なるときは式(2)で更新される。

$$q_{t+1} = \frac{((1 - \lambda_1)q_t + \lambda_2(1 - q_t))\pi_L}{\text{denominator } 1} \quad (1)$$

ここで、

$$\begin{aligned} \text{denominator } 1 &= ((1 - \lambda_1)q_t + \lambda_2(1 - q_t))\pi_L + \\ &\quad (\lambda_1 p_t + (1 - \lambda_2)(1 - q_t))\pi_H \end{aligned}$$

$$q_{t+1} = \frac{((1 - \lambda_1)q_t + \lambda_2(1 - q_t))(1 - \pi_L)}{\text{denominator } 2} \quad (2)$$

ここで、

$$\begin{aligned} \text{denominator } 2 &= ((1 - \lambda_1)q_t + \lambda_2(1 - q_t))(1 - \pi_L) + \\ &\quad (\lambda_1 q_t + (1 - \lambda_2)(1 - q_t))(1 - \pi_H) \end{aligned}$$

ただし、 $0 < \lambda_1 < \lambda_2 < 1$ かつ $\lambda_1 + \lambda_2 < 1$ である。

式(1)と(2)はいずれも q_t についての一次分数変換であるから下記の様に整理できる。なお、それぞれの係数は表2の通りである。

$$q_{t+1} = \frac{aq_t + b}{cq_t + d} \quad (3)$$

次節では、このモデルを基にしたGAsのモデルを紹介する。

3. モデルの概要

エージェントは市場の状態を判断するための変数——judge——と、状態に応じた予測変数——stable₊、stable₋、unstable₊、unstable₋——を持つ。各変数はバイナリ・ビットであり、それぞれ以下の意味を持つ:

- judge

1ならば市場は安定であるとエージェントは判断し、0ならば不安定であると判断する。

- stable₊、stable₋、unstable₊、unstable₋

stable₊は、前期のリターンが+1で、かつ市場が安定であるとエージェントが判断したときに利用される変数である。こ

の変数が1ならば次期のリターンは+1であるとエージェントは予測するのに対し、0ならば-1のリターンであると予測する。他の変数も同様である。

エージェントはまずjudgeによって市場の状態を判別し、その値に基づいて次期の価格変動を予測する。もしjudge=1、stable₊=stable₋=unstable₊=0、unstable₋=1であればエージェントは市場が安定であると判断し、前期のリターンからstable₊かstable₋のいずれかを選択して予測する(この場合は前期のリターンに関係なく下落と予測する)。価格変動(リターン)の与え方は、次節に譲る。

適合度の計算は二通りある。一方は価格変動を当てれば市場の状態判断にかかわらず+1が得られる方法であり、もう一方は市場の状態も当てて+1が得られる方法である。

学習は単純遺伝的アルゴリズムであり、これはGoldberg[6]を基にしている。

4. シミュレーションの実行と係数の推定

前節のモデルがMISを記述できるかを知るために、四種類の特定の価格列をそれぞれ繰り返しエージェントに与えて、バイナリ・ビット列のjudgeの推移を測定した^(注1):

価格列1 - - - - + ++

この価格列は、どの連続した三期間を取り出しても異なる価格列が得られるように組み合わせたものであり^(注2)、準乱数で与えた価格変動のリターンに近い。言い換えれば、この価格列は必要最低限の多様性を持っている。

価格列2 +-

この価格列は過去二期間の価格変動が常に異なるように与えており、もしエージェントの学習が期待通りになされていればある値に収束しているはずである^(注3)。すなわち、価格列2を与え続けたときの理論上の収束点は、 $q_{t+1} = q_t$ として(3)式を解けば、

$$q = \frac{(a-d) \pm \sqrt{(a-d)^2 + 4bc}}{2c} \quad (4)$$

と得られるはずである。ただし、 $0 < q < 1$ である。

価格列3 ++-

価格列4 +++-

価格列3は価格列4よりも上昇傾向は強そうだが、価格変動の同異だけを比較すれば、価格列4の方が同じ価格変動を与えた回数が多い。

後程詳しく述べるが、これら四種類の価格列を与えることで、エージェントの市場への見方がBarberisらのモデルで記述されたように推移するのかどうかを検証できる。具体的には、多様なリターン(価格列1)や一様なリターン(価格列2)にエージェントが対応できるのかをまず見る。それが出来れば、GALを用いてMISを記述できるということである。そしてその結果が妥当であるのかどうかを、価格列3と4により検証する。

(注1)：価格を外生変数としたGAsのモデルはLettau[10]にも見られる。

(注2)：順に-+-、+-+、---、--+、-++、+++、++-、+-+である。

(注3)：勿論、対称性により++を与えて良い。

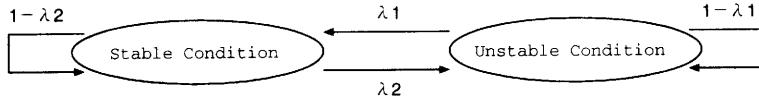


図 1 投資家の認識推移の概要
Fig. 1 An abstract of investor's recognition.

表 1 投資家心理のモデルの推移確率

Table 1 Transition probability of the MIS.

異なるリターン	$y_{t+1} = 1$	$y_{t+1} = -1$	同じリターン	$y_{t+1} = 1$	$y_{t+1} = -1$
$y_t = 1$	$\pi_L (< 0.5)$	$1 - \pi_L$	$y_t = 1$	$\pi_H (> 0.5)$	$1 - \pi_H$
$y_t = -1$	$1 - \pi_L$	π_L	$y_t = -1$	$1 - \pi_H$	π_H

表 2 式 (3) の係数
Table 2 Coefficients of eq. (3).

	a	b	c	d
式 (1)	$(1 - \lambda_1 - \lambda_2)\pi_L$	$\lambda_2\pi_L$	$(1 - \lambda_1 - \lambda_2)(\pi_L - \pi_H)$	$\lambda_2\pi_L + (1 - \lambda_2)\pi_H$
式 (2)	$(1 - \lambda_1 - \lambda_2)(1 - \pi_L)$	$\lambda_2(1 - \pi_L)$	$(1 - \lambda_1 - \lambda_2)(\pi_H - \pi_L)$	$\lambda_2(1 - \pi_L) + (1 - \lambda_2)(1 - \pi_H)$

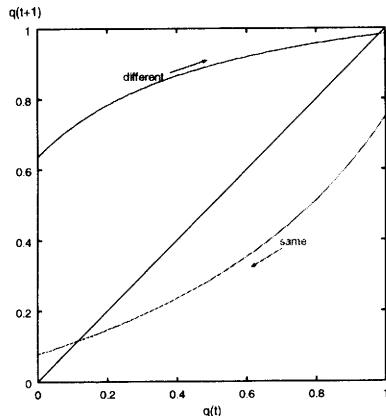


図 2 式 (3) の模式図と収束点
Fig. 2 Sketch of eq. (3) and convergent points.

このシミュレーションは下記の条件で行われ、それぞれ百本のサンプルパスを発生させた。

エージェント数 100

サンプルパスの長さ 10000 期間

適合度の与え方 前述の二種類

学習の頻度 每期 または 19 期間毎

ここでは Arthur らの研究 [2] と同様に、学習頻度によって結果に違いがあるのかを見た。19 の根拠は、四種類の価格列の長さと互いに素であることによる^(注4)。

親の選択条件（参照期間） 当期の適合度 または 過去 19 期間の適合度の和 または 過去全期間の適合度の和

交叉 (pcross) 0.6 または 0.8

突然変異 (pmutate) 0.01 または 0.05

発生させたサンプルパスから表 2 の係数を推定するために、以下の手続きを踏んだ。

(1) 48 種類のサンプルパス全てで、バイナリ・ビット列の個々の変数の平均値および分散を各期間毎に計算した。

(2) バイナリ・ビット列のうち、judge が価格列 2 を与えたときに収束しているのかどうかを調べた。

(3) 上の条件を満たしたものに限り、価格列 1 を与えたサンプルパスから最終 200 (学習) 期間の judge を取り出し、後述の手法で係数を推定した。

(4) 得られた係数から、価格列 3 と 4 を与えたときの認識確率 q_t の推移とシミュレーション上の変数 judge の推移とを比較した。

係数の推定手法は下記の通りである。

(1) 価格列 1 (-+---+++) のうち、二期連続して異なるリターンを与えられたとき (+-+ である 2 番目と -+- である 3 番目、これを d と表す) の judge と、二期連続して同じリターンを与えられたとき (--- である 5 番目と +++ である 8 番目、これを s と表す) の judge を係数の推定に用いた。

(2) d および s に対して、学習前の judge と学習後の judge との組合せをそれぞれ最終 50 組 (200 (学習) 期間のうち) 取り出した (式 (5), (6))。同様に、価格列 2 の収束点も最終 200 (学習) 期間の平均値により推定した。

- 価格変動が異なるものの組合せ

$$\text{Diffset} = \{(diff_{t_1}, diff_{t_1+1}), \dots, (diff_{t_{50}}, diff_{t_{50}+1})\} \quad (5)$$

- 価格変動が同じなものの組合せ

$$\text{SameSet} = \{(same_{t_1}, same_{t_1+1}), \dots, (same_{t_{50}}, same_{t_{50}+1})\} \quad (6)$$

(注4) : つまり、7 期間でも 11 期間でも良い。

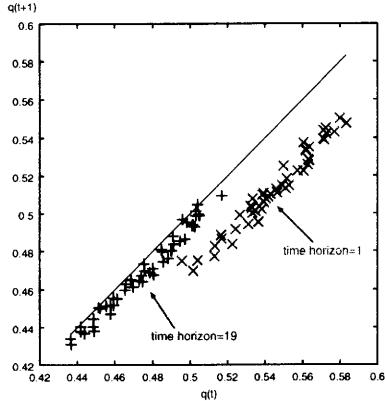


図 3 参照期間の違いによる *judge* 変化の相違 ((6) 式)

Fig. 3 Differences of *judge*(6).

- 収束点

$$Diffconv = (q, q) \quad (7)$$

$$Sameconv = (1-q, 1-q), (q > 1-q) \quad (8)$$

(8) はバイナリ・ビット列の対称性による。

ただし、 $diff_t \geq diff_{t+1}$ ($diff_t, diff_{t+1} < q$) や $same_t \leq same_{t+1}$ ($same_t, same_{t+1} > 1-q$) となるものは除外した。

(3) (5) の二点と (7)、および (6) の二点と (8) により、それぞれの一次分数変換の係数比をそれぞれ b を基準として求める。それらを順に、 $a_{diff}^*, c_{diff}^*, d_{diff}^*$, $a_{same}^*, c_{same}^*, d_{same}^*$ とする。

(4) 前項で得られた係数比のうち、境界条件 $\frac{c_{same}^* + b_{same}}{c_{same}^* + d_{same}} < \frac{c_{diff}^* + b_{diff}}{c_{diff}^* + d_{diff}}$ ($q_t = 1$) と $\frac{b_{same}}{d_{same}} < \frac{b_{diff}}{d_{diff}}$ ($q_t = 0$) を満たさないものは除外する。

(5) $\frac{c_{diff}^*}{a_{diff}^*} = \frac{\pi_H - \pi_L}{1 - \pi_L}$ と $\frac{c_{same}^*}{a_{same}^*} = \frac{\pi_L - \pi_H}{\pi_L}$ により π_L と π_H を求め、 $0 < \pi_L < 0.5 < \pi_H < 1$ を満たさないものは除外する。続いて、 $\frac{b}{d}$ から λ_2 を、最後に a^* から λ_1 を求め、 $0 < \lambda_1 < \lambda_2 < 1$, $\lambda_1 + \lambda_2 < 1$ を満たすかを調べる。

(6) 得られた λ_1 , λ_2 , π_L , π_H から表 2 の係数を再計算し、一次分数変換を確定させる。最適な一次分数変換を得るために、点集合 (5) と (6) の全ての点で絶対誤差の和を集計し、それが最も小さい組合せをそのパラメータ・セットでの MIS とする。

48 種類のパラメータ・セットのうち、価格列 2 で *judge* が収束したのは、交叉 *pcross*, 突然変異 *pmutate*, 学習頻度に関係なく、親の選択条件が当期の適合度或は過去 19 期の適合度の和であるものであった。更に係数の推定、変数の確定を行ったところ、MIS として表現できたのは、当期の適合度で親を選択するパラメータ・セットのみであった(表 3)。これは図 3 にもあるように、参照期間を長く採ればエージェントの予測率が平均化されるために、適切な一次分数変換式を構成できないからであると思われる。

変数が確定したパラメータ・セットを比較して、以下のこと

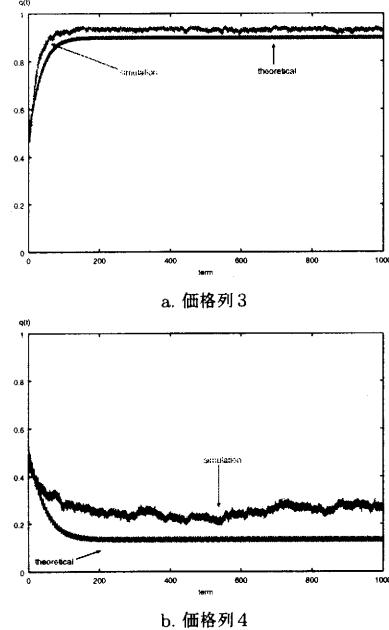


図 5 q_t の比較 ($pcross = 0.8$, $pmutate = 0.01$, 学習頻度: 毎期)

Fig. 5 Differences of q_t ($pcross = 0.8$, $pmutate = 0.01$, Learning: every period).

が得られた:

- 突然変異 *pmutate* の値によって λ_1 と λ_2 のオーダーが異なる。これは大きな *pmutate* がエージェントの多様性をもたらしているからで、その結果収束点が (0.5, 0.5) に近付いている(図 4a と b)。

- 交叉 *pcross* の相違は各変数に大きな影響を与えてはいないが、*pcross* が大きいと収束点が端点に近付く(図 4a と d)。つまりここでは、GAs の特徴の一つである多様性の制限が働いていると見做せる。

- 学習頻度の相違は π_L と π_H の相違をもたらす。推移変化図 4a と c では一見して区別はつかないが、収束点と端点との距離は学習頻度に依存している(表 3)。

最後に、表 3 で得られた変数の組合せで、価格列 3 と 4 を与えたときの q_t と *judge* の推移を比較したのが図 5 である($pcross = 0.8$, $pmutate = 0.01$, 学習頻度: 毎期, 1000 期間まで)。この図からも明らかのように、シミュレーションで得られた *judge* と推定された変数から導かれる理論上の認識確率 q_t の推移に大差はない⁽¹⁵⁾。したがって、MIS の変数は価格列 1 を与えた GAL モデルから推定される限り、他の価格列でも認識確率は同様に再現できることが示された。これは、他のパラメータ・セットでも同様であった。

以上より、GAL で MIS を説明するためには、

- エージェントには市場の状態を何らかの形で教える必要がある。

(注5) : 例えば図 5b はお互い乖離しているように見えるが、少なくともどちらも 0.50 よりは明らかに低い。

表 3 パラメータ・セット毎に推定された変数と理論上の収束点

Table 3 Deduced variables by GAL and theoretical convergent points.

p_{cross}	p_{mutate}	学習頻度	λ_1	λ_2	π_H	π_L	収束点 (7)
0.6	0.01	1	4.17×10^{-3}	4.86×10^{-3}	0.517	0.468	0.961
0.6	0.01	19	4.36×10^{-3}	4.67×10^{-3}	0.505	0.458	0.956
0.6	0.05	1	3.51×10^{-2}	4.01×10^{-2}	0.536	0.477	0.799
0.6	0.05	19	3.76×10^{-2}	3.83×10^{-2}	0.514	0.464	0.751
0.8	0.01	1	3.98×10^{-3}	4.43×10^{-3}	0.510	0.451	0.968
0.8	0.01	19	5.66×10^{-3}	5.66×10^{-3}	0.506	0.436	0.961
0.8	0.05	1	3.55×10^{-2}	3.88×10^{-2}	0.542	0.464	0.832
0.8	0.05	19	3.49×10^{-2}	3.72×10^{-2}	0.505	0.435	0.810

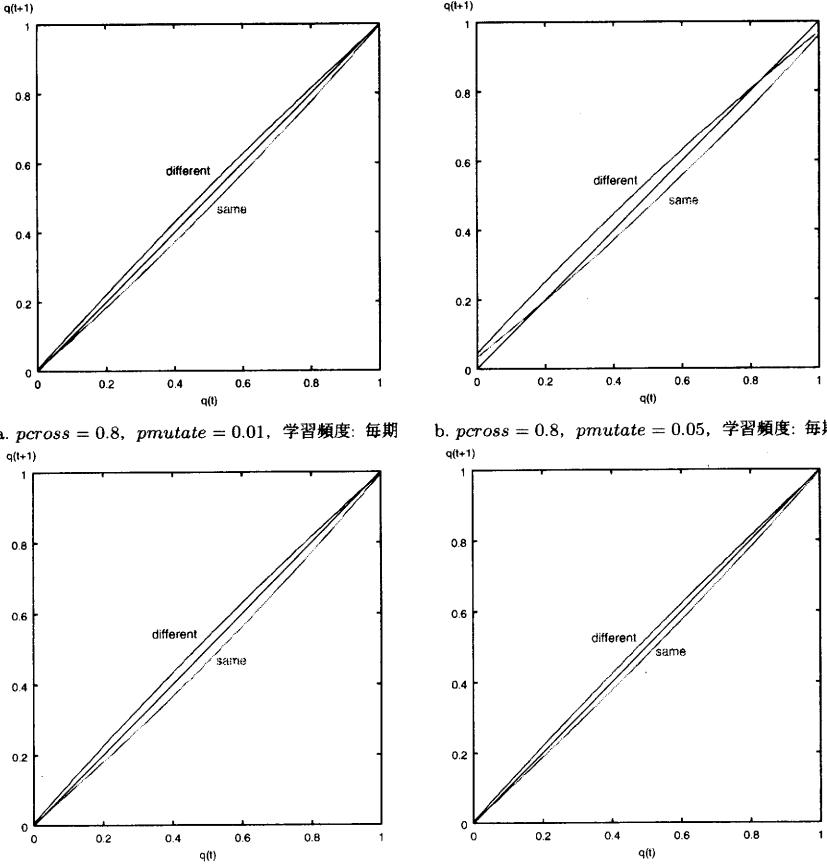


図 4 GAL により記述できた MIS の一部

Fig. 4 A part of obtained MIS by GAL.

- 適合度を用いて親の選択を行う際には、適合度の情報は常に最新でなければならない。

が求められる。そして説明できたパラメータ・セットに関しては、典型的な価格列をエージェントに与える限り、シミュレーションでの *judge* の推移と理論的な認識確率 q_t は一致する。

ところで、Miwa and Ueda は日本の株式市場（日経平均株価）の日次データから MIS の変数を $\lambda_1 = 0.001$, $\lambda_2 = 0.008$,

$\pi_L = 0.31$, $\pi_H = 0.69$ と推定している[12]。この数値とシミュレーション結果とを比較して分かることは、

(1) 実データの π_L と π_H はいずれもシミュレーションで得られた値よりも 0.5 から乖離しているため、一次分数変換 (3) は豊かな放物線を描く（図 6）。

(2) しかし、いずれの結果も $\pi_L + \pi_H = 1$ を満たすような値を取っているために、(1) と (2) は $q_t = q_{t+1}$ に関して対

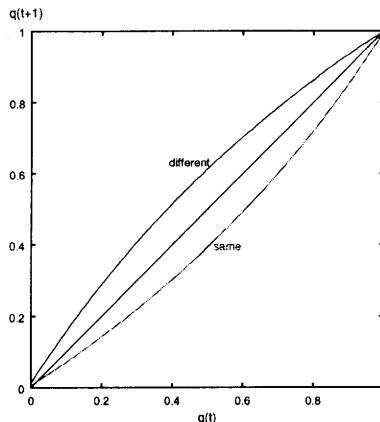


図 6 日経平均株価を説明する投資家心理のモデル
Fig. 6 A MIS which represents Nikkei225.

称な曲線となる。

(3) λ_1 と λ_2 については、シミュレーションで推定できたパラメータ・セットのうち $p\text{mutate} = 0.01$ から得られた数値に関してはオーダーは異ならない。

(4) 図 6 の収束点はいずれも端点の近傍に存在している。これらの点から考えると、シミュレーションで推定できたパラメータ・セットのうち、実データとして検証に耐えられるのは $p\text{mutate} = 0.01$ から得られた数値であるといえる。つまり、多様性の生成に用いられる GAs もその程度には限度があることをこの結果は示唆している。

である。したがって、Barberis らは自らの論文の中で $\lambda_1 = 0.1$, $\lambda_2 = 0.3$, $\pi_L = 1/3$, $\pi_H = 0.75$ と設定しているが（図 2），実データを説明するためには更なる条件が必要であろう。

5. 結 論

この論文で、投資家心理のモデルを遺伝的アルゴリズムのモデルが説明できるのかを試みた。そのために、GAs に関する様々なパラメータの組合せについて、典型的な価格列をエージェントに与え、エージェントの市場に対する見方の推移から、MIS が記述できるための条件を探った。その結果、学習に関して以下の二条件が必要であることが得られた。まず、適合度の計算にはそのときの価格変動だけでなく市場の状態も含めて考慮する必要があった。次に、エージェントが親を選択する際には、過去の履歴よりは当期の予測が当たったエージェントの予測手法を用いる必要があることであった。

最後に、今回のモデルと結果を一般的な複雑系経済学モデルに適用するための注意点を述べる。まず、市場の状態をエージェントに外部から教示するのは不自然であるので、何らかの指標が必要となるだろう^(注6)。その上で、Brock and Hommes が展開しているトレンド・チェーザやコントラリアンが存在するモデル[5]に適用することなどが考えられる。次に、親の

選択ではタイム・ホライズンを長く探ると MIS を説明できないことをこれまで示したが、一般的にはより儲かった投資家の手法を参照、模倣することが実際の市場で見られている。したがって、モデルを構築する際にはタイム・ホライズンの違いが市場や市場参加者の振舞の違いに繋がることも考慮する必要があるだろう（Blume and Easley [4]）。

文 献

- [1] J. Arifovic, R. Gencay, "Statistical Properties of Genetic Learning in a Model of Exchange Rate", Journal of Economic Dynamics and Control, vol.24, no.5–7, pp.981–1005, June 2000.
- [2] W.B. Arthur, J. Holland, B. LeBaron, R. Palmer, P. Tayler, "Asset Pricing Under Endogenous Expectations in an Artificial Stock Market" in W.B. Arthur et al. editor, The Economy as an Evolving Complex Systems II, Addison-Wesley, Reading, MA, pp.15–44, 1997.
- [3] N. Barberis, A. Shleifer, R. Vishny, "A Model of Investor Sentiment", Journal of Financial Economics, vol.49, no.3, pp.307–343, September 1998.
- [4] L. Blume, D. Easley, "Evolution and Market Behavior", Journal of Economic Theory, vol.58, no.1, pp.9–40, October 1992.
- [5] W.A. Brock, C.H. Hommes, "Heterogeneous Beliefs and Routes to Chaos in a Simple Asset Pricing Model", Journal of Economic Dynamics and Control, vol.22, no.8–9, pp.1235–1274, August 1998.
- [6] D.E. Goldberg, Genetic Algorithms in Search, Optimization and Machine Learning, Addison-Wesley, Reading, MA, 1989.
- [7] K. Izumi, K. Ueda, "Phase Transition in a Foreign Exchange Market: Analysis Based on an Artificial Market Approach", IEEE Transactions on Evolutionary Computation, vol.5, no.5, pp.456–470, October 2001.
- [8] C. Lawrenz, F. Westerhoff, "Modeling Exchange Rate Behavior with a Genetic Algorithm", Computational Economics, vol.21, no.1, pp.209–229, June 2003.
- [9] B. LeBaron, "Agent-Based Computational Finance: Suggested Readings and Early Research", Journal of Economic Dynamics and Control, vol.24, no.5–7, pp.679–702, June 2000.
- [10] M. Lettau, "Explaining the Facts with Adaptive Agents: The Case of Mutual Fund Flows", Journal of Economic Dynamics and Control, vol.21, no.7, pp.1117–1148, June 1997.
- [11] T. Lux, "Herd Behavior, Bubbles and Crashes", The Economic Journal, vol.105, no.431, pp.881–896, July 1995.
- [12] K. Miwa, K. Ueda, "The Influence of Investor Sentiment on the Formation of Golden-cross and Dead-cross", The AAAI-02 Workshop on Multi-Agent Modeling and Simulation of Economic Systems, WS-02-10, pp.54–59, Edmonton, Alberta, Canada, July 2002.
- [13] T. Riechmann, "Genetic Algorithm Learning and Evolutionary Games", Journal of Economic Dynamics and Control, vol.25, no.6–7, pp.1019–1037, June 2001.
- [14] B.R. Routledge, "Genetic Algorithm Learning to Choose and Use Information", Macroeconomic Dynamics, vol.5, no.2, pp.303–325, April 2001.
- [15] A. Tversky, D. Kahneman, "Judgement under Uncertainty: Heuristics and Biases", Science, vol.185, pp.1124–1131, September 1974.

(注6)：例として、チャート分析が挙げられるが、ノイズ・トレーディングと分類されることもある（Lux [11]）。