

株価変動の進化的最適化に基づく人工市場の構築

山根 裕明[†], 原 章[†], 長尾 智晴^{††}

本論文では、実際の市場の株価変動に類似した変動を見せる人工株式市場を構築し、実際の市場メカニズムの解析への応用を目指す。本研究では、市場を構成する各エージェントのとりうる戦略を木構造プログラムで表現し戦略の自由度を上げるとともに、エージェントの行動の解析、さらには市場全体の特徴の説明を行いやすいノード設定について検討した。また、最適化の効率向上を目的として、遺伝操作や木の表現・参照方法の改良を行い、木の参照回数を利用した処理を提案した。そしてこれらのエージェント群の株式売買によって得られる株価の変動が、実際の株式市場の変動の特徴に類似するように、遺伝的プログラミングを用いて市場の最適化を行った。さらに得られた市場を用いて追加実験を行うことによって、バブルの発生、崩壊の現象について考察した。

Construction of an Artificial Market Based on an Evolutionary Optimization of Stock Price Change

HIROAKI YAMANE,[†] AKIRA HARA[†] and TOMOHARU NAGAO^{††}

In this paper, we propose a new method to construct an artificial stock market composed of multi-agents whose investment strategies are represented by tree-shaped programs. The market is optimized by using a Genetic Programming so that the change of its stock price resembles that of "real" stock market statistically. First, we improve genetic operators and introduce a method that uses frequency of reference of partial trees for efficient optimization. In addition, to make analysis of trees easier, we modify the setting of functions and terminals. We show experimentally that complex changes like real market often appeared in the proposed artificial market. Moreover, we consider the generation and burst of the economic bubble using an acquired market.

1. はじめに

古典経済学において想定されている効率市場仮説モデルでは、投資家の価格予想に対して合理的期待を仮定しており、市場価格は利用可能で重要な情報をすべて適切に反映しているとされる。このようなモデルでは、株式市場に見られるような激しく複雑な変動を予測することはもちろん、これらの現象を説明することも困難である。

これに対して近年では、計算機内に経済活動を行う

エージェントを作成し、これらのエージェント群の取引行動によって起こる現象を観察することで実際の世界の経済現象の解析に応用する人工株式市場モデルの研究が行われている^{1)~5)}。

従来多くの人工株式市場モデルにおいて、各エージェントは過去の変動等のデータから利益が上がる戦略を学習し、取引を行っている。これらの問題点と本研究の方向性を次に示す。

- 「預貯金の利子と株の配当の比較を行うモデルが多い」

従来モデルの多くはつねに利子と配当の大小関係を考慮に入れた予測を立て、利子に対してどの程度利益を得ることができるかを前提として株式の売買を行っている。しかし市場では、売買によって得られる差額を目的として取引を行う投資家が多く存在しており、つねに利子と配当の比較を行うことが適当であるとは考えられない。

したがって、本研究では利子と配当を比較しないモデルで、複雑な変動を獲得できる人工株式市場の構

[†] 東京工業大学大学院総合理工学研究科物理情報システム創造専攻
Department of Information Processing, Tokyo Institute of Technology

^{††} 横浜国立大学大学院環境情報研究院
Faculty of Environment and Information Sciences,
Yokohama National University
現在、松下電器産業株式会社
Presently with Matsushita Electric Industrial Co., Ltd.
現在、広島市立大学
Presently with Hiroshima City University

策を行う。

- 「市場を判断するルールやその基準は市場設計者が与えている」

従来研究において、投資家の戦略は classifier system や遺伝的アルゴリズムで記述されていることが多く、市況を判断するルール・基準は市場設計者が与えている。このような前提では、市況判断方法・基準の多様性やその影響等を認識することができない、という問題が起きる。

したがって、本研究ではエージェントの戦略決定に自由度を持たせるために、遺伝的プログラミング (Genetic Programming; GP) を用いる。さらに市場の解析が行いやすいような GP の記号設定を行う。

- 「価格変動自体について評価を行っていない」
- 進化的計算法を用いた人工株式市場の研究では、エージェントの行動を評価して利益が上がるように最適化を行うものが多い。しかしその一方で、エージェント群の取引行動の結果として得られる市場の評価、つまり株価の変動について言及しているものは少ない。

したがって、本研究ではエージェントの行動や利益は考慮に入れず、エージェント群により構成される人工市場の株価変動が、実際の市場の変動の特徴に類似するように最適化を行う。すなわち、エージェント群全体を GP における 1 個体とし、市場全体の最適化を行う。

この手法は、人工社会のエージェント群を現実の社会指標に一致させるように進化させ、その結果得られたエージェント群を解析することにより、その社会現象の発生要因を解明するという逆問題的なアプローチである。文献 6) では、このアプローチが電子コミュニティのネットワーク構造分析に適用され、マクロ社会現象の創発の解明手段として有効であることが示されている。本研究では、社会指標として株価変化率に関する統計量を採用し、株価変動メカニズムの解明を目指す。

以上のように本研究では、エージェント群の株式売買によって得られる株価の変動が、実際の株価変動の特徴に類似するように、GP を用いて市場の最適化を行う。さらに得られた市場を用いて追加実験を行うことによって、実際の市場に起こる現象のメカニズムの解析を目指す。

本論文の構成は以下のとおりである。2 章では、効率的な戦略形成のための、遺伝操作の改良と参照回数利用処理方法について述べる。さらに実際の株価変動の学習実験によって有効性を示す。3 章では、人工株

式市場を構築し、実際の株式市場の変動の特徴に類似するように最適化する。さらに得られた市場に対して追加実験を行い、考察を述べる。4 章では、本論文で得られた結果のまとめと今後の課題について述べる。

2. GP を用いた効率的な戦略形成手法

2.1 戦略の形成手法

2.1.1 取り扱う金融時系列データ

株価の上下をデータとして取り扱う場合、株価自体や株価の変化量を直接扱うと自己相関が高くなる等の問題があるため、株価変化率を計算して扱う方が一般的である。株価変化率は、時間 t における株価 $Price(t)$ を用いて

$$Change(t) = \frac{Price(t) - Price(t-1)}{Price(t-1)} \quad (1)$$

と定義される。

また従来、金融時系列データを GP で扱う場合は、終端記号は 1~10 期前の値、非終端記号は四則演算や \sin, \cos 等の三角関数で構成されている場合が多い^{7)~9)}。しかしこれらの研究のように、2 つの変化率の乗算や、三角関数への株価や株価変化率の代入は、市場の動きを解析するうえで、その戦略の意味付けが困難となる。

そこで本研究では、

- 戦略は株価変化率を用いて形成する、
- 過去の変動に関する値を参照して予測を行う、
- 予測戦略の解析が行いやすい GP の終端・非終端記号を設定する、

という方針で戦略形成を行う。

2.1.2 投資家の戦略の GP による効率的な最適化

最適化を効率的に行うために以下の方法を考える。

- (1) 戦略木の多様性維持のための遺伝操作
たとえ、賢明な戦略であっても、同じような戦略ばかりが集団を構成すると、似た予測が多くなり取引が行われなくなってしまう等集団全体としての性能はかえって悪化してしまう。よって形の似た木について、親とは似ていない応答を返す子を作るように遺伝操作を行う。
- (2) 参照回数利用処理による戦略木の単純化
深く大きな木には、不要な部分木も多く含まれるため進化に悪影響を与えるとともに、木の参照にも時間がかかる。そこで、使用頻度の低い部分木に対して単純化処理を行い、効率的に最適化を行う。

(1) の遺伝操作方法について 2.2 節で、(2) の参照回数利用処理方法について 2.3 節で述べる。

2.2 遺伝操作方法

2.2.1 標準交叉と一様交叉

一般的に GP の交叉方法として知られているのは、2 つの木の部分木どうしの交換を行う標準交叉 (standard crossover) と呼ばれるものである。このとき交換する部分木はすべてのノードからランダムに選択される。

一方、文献 10) では、一様交叉 (uniform crossover) が提案されている。この交叉方法は、2 つの木を重ね合わせて位置が一致しているノードについて、ノードごとに交換率を満たす場合に、そのノードから出ている枝の数が一致していればノードの中身の交換を行い、そのノードから出ている枝の数が一致しなければノード以下の部分木の交換を行うという手法である。

一様交叉は標準交叉に比べて、木の根に近いノードの交換が行われる可能性が高く、各非終端記号の枝の数が近い場合に有効であるといわれている。

2.2.2 本研究で行う遺伝操作方法

本研究で行う交叉方法を以下に示す。

2 つの親の木に対して、

- 一様交叉可能な共通領域数: c
- 共通領域のうち実際に中身が異なるノード数: d
- 実際に異なるノードが交換される確率: $r (= d/c)$

を調べる。また、各実験では一様交叉可能となる基準として以下の定数を決定しておく。

- 最小共通領域数: c_{Min}
- 最小交換ノード数: d_{Min}
- 最小交換率: r_{Min}

そこで以下を本研究でエージェントの戦略を生成するために用いる交叉とする。

```

if ( $c < c_{Min}$ )
  then 標準交叉 /* 似ていない場合 */
  else if ( $d \geq d_{Min}$ ) & ( $d/c \geq r_{Min}$ )
    then 一様交叉 /* ある程度似ている場合 */
    else 片方を突然変異 /* 似過ぎている場合 */
  
```

このようにすることで、効率的に市場内のエージェントの戦略を最適化できると考えられる。この交叉方法の有効性を確認する学習実験について 2.4.2 項で述べる。

2.3 参照回数利用処理方法

2.3.1 GP における木の参照

条件文を含む木に関しては、まったく、あるいは、ほとんど参照されない部分木が存在する可能性がある。本研究で扱う条件文は「引数 1 と引数 2 の大小関係を調べ、その真偽により、引数 3 または引数 4 を返す」という働きを持つ。すなわち、条件文を表す木は 4 本




図 1 不要な部分木を含む木

Fig. 1 Tree including an unexecuted code.

の枝を持つ。たとえば、 x_i が i 日目の株価を表すとすると、図 1 における条件記号「if >」では、つねに引数 1 が引数 2 より大きくなるので、必ず引数 3 が参照されることになる。

このことは、木を参照するたびにそのノードの参照回数を数えるだけで簡単に調べることができる。図 1 における括弧内の数値は、その木を 100 回評価した際に、そのノードが実際に参照された回数を表しており、第 4 引数は参照されていないことが分かる。

2.3.2 参照回数を利用する処理方法

1 つの木に存在するすべての条件文ノード (i) に対して参照偏向指数、

$$b(i) = \frac{\max(c_1(i), c_2(i))}{c_1(i) + c_2(i)} - 0.5 \quad (2)$$

を計算する。ただし、

- $c_1(i)$: 行動部 1 の参照回数
- $c_2(i)$: 行動部 2 の参照回数

とする。さらに $b(i)$ について、木の根からの距離が近いほど大きくなるように補正をかけたものを処理の選択指数とし、選択指数に比例してノードを 1 つを選択する。選択されたノードに対して、以下の 2 つの操作のいずれかを行う。

- (1) 枝切り: 条件文から参照回数の多い木だけ抜き出す。
- (2) 条件突然変異: 条件記号、条件部を突然変異させる。

(1) の方法によって参照時間が短縮され、(2) の方法によって条件文の有効利用が可能になると考えられる。図 1 に示した、有効に利用されていない条件記号「if >」を含む木に対して、枝切りを行った木と条件突然変異を行った木の例を図 2 と図 3 にそれぞれ示す。このような処理により効率的に戦略の形成を行う。こ




図2 枝切りを適用した木
Fig. 2 Tree applied a cut of unexecuted code.




図3 条件突然変異を適用した木
Fig. 3 Tree applied mutation in a conditional part.

の参照回数利用処理方法の有効性を確認する学習実験について 2.4.3 項で述べる。

2.4 実験による検証

2.4.1 記号設定

ここでの実験では、変動の特徴を把握するという意味で、変化率を6段階に区切り、どこにあてはまるかを決定することで、変動のおおまかな動きをとらえることにする。ここで用いる記号を表1に示す。また、終端記号の表す値を表2に示す。

たとえば、予測木を $(rev(max\ 3))$ とした場合、予測変化率は以下ようになる。

- (1) まず $(max\ 3)$ を考える。表2の「週数」の項目から、記号3は“4週”を表す。よって $(max\ 3)$ は“過去4週間の最大変化率”を表す。ここで、仮に過去4週間の最大変化率を0.017とすると、表2の「対象変化率」の項目より、記号“4”の範囲にある。よって $(max\ 3)$ の答として“4”を返す。
- (2) さらに $(rev\ 4)$ は、変化率に関して符号を反転したものを選択することになるので、“1”を返す。

表1 GPにおける関数・終端記号の設定
Table 1 Settings of GP functions and terminals.

記号	引数	働き
if >	4	if $arg0 > arg1$ return $arg2$ else $arg3$
if >=		if $arg0 \geq arg1$ return $arg2$ else $arg3$
if =		if $arg0 = arg1$ return $arg2$ else $arg3$
if <=		if $arg0 \leq arg1$ return $arg2$ else $arg3$
if <		if $arg0 < arg1$ return $arg2$ else $arg3$
rev	1	$5 - arg0$ (±反転)
inc		$arg0 + 1$ (1段階上)
dec		$arg0 - 1$ (1段階下)
max	1	maximum value (期間内の最大変化値)
min		minimum value (期間内の最小変化値)
avg		average value (期間内の平均変化値)
chg		value (期間前の変化率)
0, ..., 5		0

表2 終端記号の表す値
Table 2 Values represented by terminals.

記号	週数	対象変化率	予測変化率
0	1	-0.02	-0.03
1	2	-0.02 ~ -0.01	-0.015
2	3	-0.01 ~ 0.0	-0.005
3	4	0.0 ~ 0.01	0.005
4	6	0.01 ~ 0.02	0.015
5	12	0.02 ~	0.03

- (3) 表2の「予測変化率」の項目から今回の予測変化率を -0.015 と予測することになる。

2.4.2 変動学習実験1

本項では 2.2 節で説明した遺伝操作方法を用いて作られた子個体の親個体との類似性について検証する。

まず、1988年4月から1995年11月までのTOPIX (Tokyo Stock Price Index, 東証株価指数) の週次の変化率に関して、各個体の応答が6段階にほぼ均等、かつ、自己相関の絶対値が0.1未満であり、また互い個体間の出力に相関がない、という条件を満たす親個体の組をGPを用いて作成し、427組の獲得に成功した。

親個体 (P_i, P_j) に交叉を行ってできた子 (C_1, C_2) からなる親と子の4通りの組合せに対して、各々の応答に対する相関係数を計算する。この4つの相関係数のうち、絶対値最大の2値の平均を、2つ親からできた2つの子の類似度と定義する。類似度は0.0~1.0で表され、0.0に近いほど親と子の応答に相関関係がないことになる。本研究では類似度は小さい値になることが望まれる。

交叉方法が親子の類似度に与える影響を検証するため、標準交叉と一様交叉の割合を、以下の5種類に変えて類似度を測定した。

- (標準交叉 : 一様交叉) = $\{(1.0 : 0.0), (0.25 : 0.75), (0.5 : 0.5), (0.75 : 0.25), (0.0 : 1.0)\}$

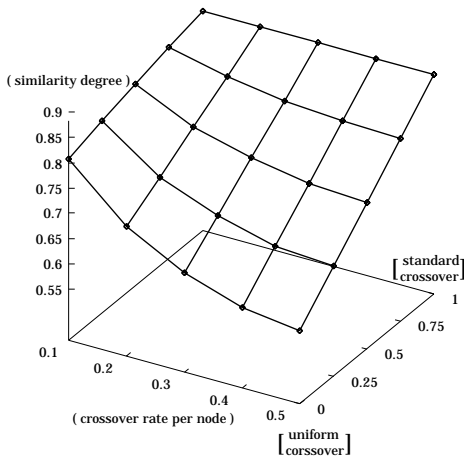


図4 交叉方法による類似度の違い

Fig. 4 Similarity degree by various settings of crossover.

また、一様交叉の各ノードにおける交換率を0.1, 0.2, ~, 0.5の5段階で実験を行った。結果を図4に示す。図4に示す類似度は、各組に対して独立に交叉を50回適用して平均類似度を求め、さらに427組の平均値をとったものである。この図から、

- 一様交叉を行う割合が高い場合、
- 一様交叉のノードの交換率が高い場合、

に親との類似度が低くなっており、親と応答の似ていない子が作られやすいことが分かる。これは、本研究のように条件文を用いる場合では、2つの親どうしの条件部の交換、あるいは、行動部の交換が行われることによって、参照する条件の組合せ、あるいは条件を判断してとる行動の組合せの違いから、2つの親とは違った応答をする子ができやすいためと考えられる。したがって市場を構成するエージェントを作成する場合の交叉方法として一様交叉は有効であると考えられる。

2.4.3 変動学習実験 2

本項では、2.3節で説明した参照回数利用処理方法の有効性を示すために、1990年3月から1993年1月までのTOPIXの週次データについて、学習を以下の4つの方法で行った。

- (1) 標準交叉と部分木突然変異を用いる。
- (2) 交叉は標準交叉と一様交叉の併用、突然変異は部分木突然変異を用いる。
- (3) 遺伝操作は(1)と同様に行い、参照回数利用処理を実行して適応度が下がらなければ適用。
- (4) 遺伝操作は(2)と同様に行い、参照回数利用処理を実行して適応度が下がらなければ適用。

学習期間での適応度は、時間 t に木から返ってきた6段階の整数値を F_t 、TOPIXの変動を表2の「対象




図5 4種類の設定における最大適応度の比較

Fig. 5 Comparison of the fitness among four methods.

変化率」に従って6段階にしたものを R_t として、以下のように定義される。

$$fitness = \frac{1}{\sum_t (R_t - F_t)^2} \tag{3}$$

実験の設定は以下のとおりである。

- 集団数：500
- 交叉率：0.7
 - (標準交叉：一様交叉) = (0.5：0.5)
 - 一様交叉のノードごとの交換率：0.1
- 突然変異率：0.4
- 参照回数利用処理適用率：0.2
 - (枝切り：条件突然変異) = (0.5：0.5)

また、世代交替モデルには MGG (Minimal Generation Gap)¹¹⁾を用いた。MGGでは、集団中からランダムに選択した2個の親個体に対して交叉・突然変異を適用することにより子個体を n 個生成し、それら $(n+2)$ 個の中から最良個体1個とルーレット選択による1個を選択して集団に戻すという操作を繰り返し、個体群を進化させる。なお、ここでは $n = 6$ として実験を行った。

実験100回の最大適応度の推移の平均を図5に示す。この結果から、以下のことが分かる。

- 「一様交叉により適応度が向上した」
- (1)と比べて(2)の方が、また、(3)より(4)の方が適応度が高い。これは、一様交叉により複雑な木を作りやすくなったことと、極似している木の片方を突然変異させることにより、局所解へ陥

る危険性を回避するすることができるようになったためと考えられる。

- 「参照回数利用処理により適応度が向上した」
 - (1) と比較して (3) が、さらに (2) と比較して (4) の方が適応度が高くなった。これは、意味のない条件文を削除、あるいは条件を変更することで、新たに有効な条件の発見が行われる可能性が高くなったことが原因だと考えられる。また、不要なノードの参照にかかる時間を削減できることから、計算時間が短縮される効果も見られた。

なお、GP では一般的に、個体群の多様性の維持、および木のサイズの制御方法が重要とされている。また、条件分岐ノードを持つ木は、人工市場問題にかかわらず、ロボット制御等の他の問題でも一般的に使用される。ここで提案した、一様交差の併用、および参照回数利用処理という操作は汎用性を持つものと考えられるが、その検証については今後の課題である。

3. 人工株式市場の構築

ここでは、本論文で構築する人工株式市場の構成および最適化方法について述べる。また、追加実験により実際の市場の解析を行った結果を示す。

3.1 人工株式市場の構成

市場内の各エージェントは、木構造で表された別々の予測戦略を持つ。各エージェントは過去の変動を参照し、自分の予測の木から得られた応答に従って予測値を決定し、取引行動を行う。

構築する人工株式市場の構成を以下に示す。

- エージェントが a 人存在する。
- 株が $a/2$ 個存在する。
- エージェントの保有できる株の最大数を 1 個として、エージェントの状態は、株を { 持っている, 持っていない } の 2 通りとする。
- エージェント (i) は予測の木と過去の変動から
 - 何日後の予測を行うか?: 予測期間 (d_i)
 - 価格をいくらに予測するか?: 予測価格 (p_i)
 を計算して市場に提示する。
- 市場は全員の予測を集計してエージェント (i) が
 - 株を持っている場合
 d_i 日以内で株が p_i 円以上 → 売る
 - 株を持っていない場合
 d_i 日以内で株が p_i 円以下 → 買う

という取引行動をとらせるようにする。すなわち、この予測価格 p_i は、エージェントが売買に参加する際の取引限度額を表しており、売り手ならばその値以上で、買い手ならばその値以下であれば取引に

応じることになる。つまり、各投資家は、自分が予測する将来価格よりも、今高く売れるならば売り、安く買えるならば買うという動作を行う。

GP の木で扱うデータは株価変化率とし、各エージェント i は自分の木から獲得した予測変化率 $c_i(t)$ と現在の株価 $Price(t)$ から、 d_i 日後の予測株価 $p_i(t+d_i)$ を以下の式に従って計算して、市場に提示する。

$$p_i(t+d_i) = (1.0 + c_i(t)) * Price(t) \quad (4)$$

各エージェントは d_i 日間は予測を変更せず、 d_i 日経ったところで木を参照し直して新たな予測を立てる。

市場はすべてのエージェントの予測を集計して、売り手側は安く売るエージェントを優先的に、買い手側は高く買うエージェントを優先的に実際に取引を成立させる。そして株価は取引量が最大になる値に決定する。このとき全員がランダムな予測を行えば、獲得される株価変化率は正規分布に従うことになる。

3.2 GP における終端・非終端記号の設定

人工株式市場を構成する各エージェントの予測の木に用いる記号を表 3 に示す。また、終端記号の表す値を表 4 に示す。

本研究における記号設定の特徴として以下の 2 点があげられる。

- (1) 条件文の条件部と行動部で、働きを変更
- (2) 過去の変動の参照の有無で、働きを変更

(1) の例として、「combi1」の処理を説明する。「combi1」は条件文の条件部では「2 つの引数の差」を返し、行動部では「2 つの引数の平均」を返す記号である。条件部の中で「2 つの引数の差」はエージェントの戦略を形成するうえで有効な操作であるといえる。しかし予測値として「2 つの引数の差」を利用することの有用性はあまり考えられない。また逆に、条件部で「2 つの引数の平均」が 0.0 より大きいかが否かを評価することも少ないと考えられる。

仮に、2 つの機能を別の記号として設定すると、条件部に「平均」する記号が、逆に行動部に「差」を求める記号が入る可能性があり、効率的に最適化を行うことが困難になると考えられる。また条件部に「平均」する記号が入らないように、逆に行動部に「差」を求める記号が入らないように構造を変更しようとする、木の生成、交叉、突然変異等のすべての過程を考慮に入れた大幅なプログラムの変更を余儀なくされる。

そこで 2 つの機能を 1 つの記号の条件部と行動部に分けることにより、必要な機能が必要な場所で使用されるようになるため、効率的に最適化が行われる。

また、(2) の例として、「combi1」が条件文の行動部にある場合を考える。このとき表 3 から「combi1」

表 3 GP における関数・終端記号の設定

Table 3 Settings of GP functions and terminals.

カテゴリ	記号	引数	条件部		行動部	
			変動参照	未参照	変動参照	未参照
0	if >= if <	3	if $arg0 \geq 0.0$ return [arg1], else [arg2] if $arg0 < 0.0$ return [arg1], else [arg2]			
1	combi1 combi2	2	$arg0 - arg1$ $arg1 - arg0$	[Random]	$(arg0 + arg1)/2$ $-(arg0 + arg1)/2$	[Random]
2	rev	1	$-arg0$	(through)	$-arg0$	(through)
	inc dec		(through)		$2 * arg0$ $arg0/2$	(through)
3	max min avg chg	2	(through)	max value min value avg value value	(through)	max value min value avg value value
4	0, 1, ..., 4	0	正規分布 $N(0.0, 0.05)$ に従う乱数を返す。参照期間, 予測期間は表 4 を参照。			

表 4 終端記号の表す値

Table 4 Values represented by terminals.

記号	過去の参照期間	予測期間
0	1日	1日
1	2日	1日
2	3日	2日
3	5日	2日
4	20日	3日

表 5 株価変化率に関する統計量

Table 5 Statistics on stock price change.

統計量	正規乱数	実際の市場
自己相関	0.0	0.05 ~ 0.1
二乗変化率の自己相関	0.0	0.4 ~ 0.6
1σ 内になる確率	0.683	0.75 ~ 0.8
3σ 外になる確率	0.003	0.01 ~ 0.02

は 2 つの引数の平均を返す。ここで、この 2 つの引数にランダムな予測が入力された場合に、2 つの正規乱数の平均を計算してしまうと、出力は違う性質の乱数になる。このような操作を許すとエージェントごとにランダムな予測の性質が異なってしまうために、解析時にランダムな予測の扱いが困難になる。そこで本設定のように、引数が過去の変動参照していなければ、改めて「combi1」においてランダムな予測を行うことで、市場に存在する「ランダムな予測」を同じ性質のものにすることが可能になる。「combi1」の具体的な計算方法は以下になる。

- 2 引数のうち 2 つとも過去の変動を参照していない場合、2 引数の変化率は無視して、新たにランダムな予測を返す。
- 2 引数のうち 1 つだけ過去の変動を参照していた場合、参照されていた方の引数からの入力をそのまま返す。
- 2 引数のうち 2 つとも過去の変動を参照していた場合、表 3 に示す処理を行う。

3.3 最適化方法

3.3.1 最適化の方針

本研究における人工市場へのアプローチは、ある特定のマクロ現象の再現度によってエージェント群全体を評価し、最適化の結果得られたエージェント群の行動を解析することにより、そのマクロ現象の発生要因

を解明するという逆問題的なアプローチである。よって、個々のエージェントの行動の評価は行わず、エージェント群の相互作用によって発生する株価変動のみを用いて人工市場の評価を行う。また評価の際には、株価変動そのものではなく、株価変化率に関する統計量を用いる。

一般的に株式市場の株価変化率について、表 5 のような特徴があることが知られている。つまり、株価変化率自体については相関性がほとんど見られないが、その 2 次モーメントについてはかなり高い相関性が見られる。また正規分布と比較すると、中央と端に偏った分布になっている。そこで本研究では「木構造の予測を持つエージェント集団から構成される市場を構築して、これらのエージェントに株の売買を行わせて得られた株価の変動が表 5 の実際の市場の統計量を満たす」ように最適化を行う。

3.3.2 市場の適応度

現実的な株価変動を見せる市場を構築するため、以下のような方法で、市場の適応度 *Fitness* を評価する。

- (1) まず 1 つの市場について取引行動を行わせ、
 - (a) 変化率が一定期間停滞
 - (b) 株価の過剰な高騰・暴落
 という条件にあてはまると取引を停止させる。また取引が途中で停止した場合の適応度は、

$$Fitness = \frac{\text{(動いた日数)}}{\text{(最大取引期間)}} \quad (5)$$

にする．つまり最後まで市場が動いた場合には，
(動いた日数) = (最大取引期間) となるので，
 $Fitness = 1.0$ となる．

- (2) もし最大取引期間まで動いた場合，得られた株
価変化率について表 5 の統計量を計算する．こ
こで実際の市場の「自己相関」「二乗変化率の
自己相関」「 1σ 内になる確率」「 3σ 外になる確
率」との誤差の 2 乗を各々 E_c, E_d, E_o, E_t
として，適応度は (1) の分を含めて，

$$Fitness = 1.0 + \frac{1.0}{S_e} \quad (6)$$

$$S_e = 10 \times E_c + 10 \times E_d + E_o + E_t \quad (7)$$

とする．つまり，誤差が小さくなるほど適応度
は大きくなる． E_* の係数は予備実験により得
られたものである．

- (3) 人工株式市場の適応度は，最初に株を分配され
るエージェントの組合せやランダムな予測に影
響を受ける可能性がある．そこで，安定した市
場を構築するため，同じ市場を 4 回動作させ，
この 4 つの適応度の中で最小の 2 値の平均を市
場の適応度とした．

3.4 実験と結果

3.4.1 実験環境設定

実験環境は以下のとおりである．なお，初期世代の
各市場におけるエージェントの予測戦略は，表 3，表 4
に示した記号群からランダムに構成した．

- エージェント数：20
- 株の数：10
- 取引期間：1000
- 市場数 (GP の個体数)：200
- 世代数：1000
- 世代交替：MGG
- 交叉率：0.7
 - － (標準交叉：一様交叉) = (0.3 : 0.7)
 - － 一様交叉のノードごとの交換率：0.5
- 突然変異率：0.4
- 参照回数利用処理適用率：0.2
 - － (枝切り処理：条件突然変異) = (0.7 : 0.3)

3.4.2 実験結果

実験により，表 5 に示した株価変化率に関する統計
量をすべて満たすような人工市場を獲得した．獲得し
た人工株式市場の変化率と株価の変動の例を，図 6，
図 7 に示す．株価変化率の変動幅が大きい区間がしば
らく続いたり，逆に小さい区間がしばらく続いたりす
るといったような傾向を持つことを確認できる．また，
得られた株価変化率に関する統計量は，




図 6 人工株式市場の変化率の推移

Fig. 6 Price change rates in an artificial market.

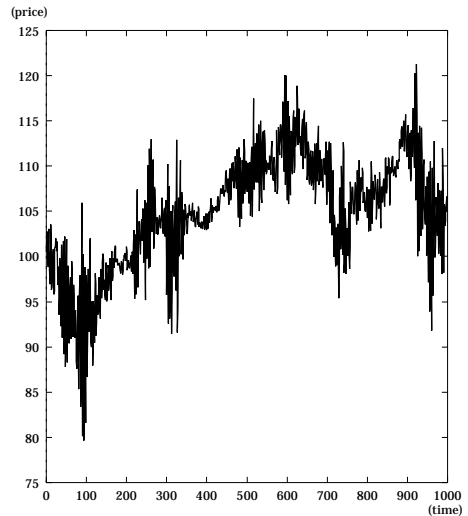


図 7 人工株式市場の株価の推移

Fig. 7 Time series of stock price in an artificial market.

- 自己相関：0.0744
- 二乗変化率の自己相関：0.479
- 1σ 内になる確率：0.756
- 3σ 外になる確率：0.011

となっており，いずれも実際の市場の条件を満たして
いる．また，最適化の過程では 1,000 日間の取引によ
る評価であったが，獲得された市場で，1,000 日以降
も引き続き取引させ，10,000 日という長い期間で統計
量を計測したところ，その特性は崩れずに，市場統計
量を満たすことを確認した．

また，この人工株式市場を解析したところ，以下の
ような特徴を持つことが分かった．

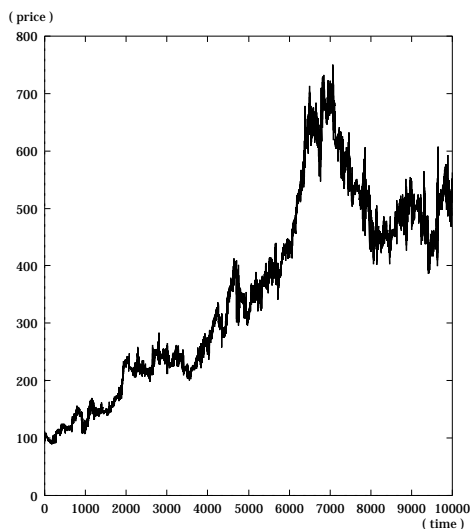


図8 バブルを起こした人工株式市場の株価の推移

Fig. 8 Stock price change showing an economic bubble.




図9 ランダムな予測がプラスである確率 ($\bar{r}p(t)$)

Fig. 9 Probability that random forecast is positive.

- ランダムな予測が市場全体の 30%を占めていた .
- 過去の変動の 2 倍を予測値とするエージェントが多く存在した . これらのエージェントが変動に過剰に反応することが , 二乗変化率の自己相関が高くなったことの 1 つの要因であると考えられる .
- 過去一定期間における株価の最大変化率の 1/2 倍を予測値とするエージェントが存在した . これは大きな変動を抑制する働きを担っていると考えられる .

なお , 表 5 の統計量をすべて満たす市場として , ここで得られた市場とは異なる構成の市場が存在する可能性も考えられる . しかし , 今回の実験では , 異質な 20 エージェントからなる市場を最適化する必要があり探索領域が膨大なため , 異なる構成の市場を獲得することはできなかった . 次節では , ここで得られたエージェント群を市場の一例として用いて , 株価変動に関する考察を行う .

3.5 考察

3.5.1 人工株式市場で起こるバブル

前節で獲得された市場を何回か動かしていたところ , 図 8 のように , バブルが発生して崩壊するような変動を見せるものが現れた . この得られた変動について表 5 の 4 つの統計量を計算したともし , 実際の市場の条件を満たしていることを確認した .

またこのときのランダムな予測について調査を行った . ランダムな予測のうちプラスに予測する確率 $rp(t)$ を調べ ,

$$\bar{r}p(t) = \frac{\sum_{i=-500}^{1000} rp(t+i)}{1000} \quad (8)$$

(ただし , $500 \leq t < 9500$)

を計算した . この結果を図 9 に示す . この図の数値は , 市場内のランダムな予測のうちプラスに予測する割合が多いほど大きく , マイナスに予測する割合が多いほど小さくなる . つまり区間 (5500 ~ 7000) においてバブルが発生しているのはランダムな予測がプラスに偏っていること , さらに区間 (7000 ~ 8000) においてバブルが崩壊しているのはランダムな予測がマイナスに偏っていることが , 各々の原因である可能性が考えられる .

そこで , 乱数を操作してバブルを起こしやすい状況を作り出してみる . ランダムな予測は平均 0.0 , 標準偏差 0.05 の正規乱数を返す設定であるが , ここで全区間 (0 ~ 10,000) のうち ,

- 区間 (5000 ~ 6500) : 平均 0.01
- 区間 (6500 ~ 8000) : 平均 -0.01

に変更して実験を行うことにする . このとき , 区間 (5000 ~ 6500) では景気の見通しが明るく , 投資家の購入意欲が高い状況で , 区間 (6500 ~ 8000) では逆に景気の加熱感が高まり , 投資家の購入意欲が低下した状況と見なすことができる . 取引を行わせた結果 , 図 8 と同様なバブルの再現に成功した . また , 表 5 に示した株価変化率に関する 4 つの統計量を調べたところ , 実際の市場の条件を満たしていることを確認した . したがって , 実際の株式市場に見られる特徴である 4 つの統計量を満たしていてもバブルは再現可能であるこ




図 10 TOPIX における株価変動
Fig. 10 Time series of stock price in TOPIX.

表 6 TOPIX における統計量の比較
Table 6 Comparison of statistics on TOPIX.

統計量	(区間 1)	(区間 2)	(区間 3)
自己相関	0.132	0.119	0.182
二乗変化率の自己相関	0.323	0.492	0.164
1 σ 内になる確率	0.803	0.834	0.780
3 σ 外になる確率	0.0186	0.015	0.017

とが分かった。

3.5.2 日本のバブルとの比較

実際のバブルとの比較のため、図 10 に示す TOPIX (1969 年 1 月 7 日 ~ 1997 年 7 月 4 日, データ数: 6980) の変動と前節で獲得された変動の比較を行う。

TOPIX のデータにおいて、

- (区間 1) 全区間 (0 ~ 6979)
- (区間 2) バブル生成時期 (4000 ~ 5000)
- (区間 3) バブル崩壊時期 (5000 ~ 6000)

の各々の区間について、価格変化率の統計量を調べた結果を表 6 に示す。

得られた結果から、以下の 4 つの条件

- (1) バブル生成時期の自己相関が小さい、
- (2) バブル生成時期の二乗変化率の自己相関が大きい、
- (3) バブル崩壊時期の自己相関が大きい、
- (4) バブル崩壊時期の二乗変化率の自己相関が小さい、

が成立しているものとして、人工株式市場でも同様な条件が成立しているか否かを検証した。3.4 節で獲得した市場において、前項で述べたようにランダム予測に偏りを与えバブルを示す市場を獲得するという方法で、異なる乱数系列を用いて作成した 50 個の市場に

対して、統計量を調べたところ、各々の条件を満たす確率は、

- (1) 78% (2) 36% (3) 78% (4) 80%

となっており、(1) ~ (4) がすべて成立していた市場は全体の 24% であった。

特に (2) の条件については低い値を示した。本実験で得られた、過去の変動の 2 倍を予測値とするものやランダム予測を行うものからなるエージェント群の相互作用による株価変動では、バブル生成時期に二乗変化率の自己相関が高いという現象が現れにくいことが分かる。バブル生成時期には、過去の 2 倍を予測値とする戦略に多くの投資家が一時的に偏るといった、より戦略的な行動等も考慮する必要があると考えられる。

一方、条件 (3), (4) については、高い値を示した。すなわち、ランダム予測の平均を -0.01 とすることにより、実際の市場におけるバブルの崩壊時期と似た状況を作り出すことができた。このような偏りを持つランダム予測は、投資家の購入意欲が低下した状況と考えることができる。

人工市場におけるこのような結果から、実際の市場においては、

- バブル生成時期では投資家は、より戦略的で、変動に過剰に反応していた、
- バブル崩壊時期では投資家は戦略をとれないような状況に陥り、ファンダメンタルが低い等の理由のために購入意欲が低くなり、価格が暴落した、と推測される。

4. おわりに

本研究では、計算機内に木構造で表される戦略を持つエージェントを作成して、これらの株式取引の結果得られる株価の変動が、実際の株式市場の変動の特徴に類似するように最適化することを目指した。

まず、市場を構成するエージェントを対象とした効率的な戦略形成手法として、改良した遺伝操作方法と参照回数利用処理方法を提案し、さらに実際の変動の学習実験により、各々の手法の有効性を示した。

次にこれらの手法を用いて人工株式市場の構築を行った。エージェント群の株式売買によって得られる株価変化率について、実際の市場の持つ統計量との誤差が小さくなるように最適化を行った。このとき GP の記号設定の工夫として、過去の変動を参照したか否かで、また条件文の条件部と行動部でそれぞれ記号の働きを変えることにして、解析の簡略化と最適化の効率向上を図った。

さらに得られた市場を用いた追加実験では、ランダ

ムな予測を操作して、景気の見通しが明るい時期と景気の加熱感が高まった時期を設けて取引を行わせ、バブルに似た変動を作り出すことに成功した。しかもこの変動は実際の市場の条件を満たす可能性があることが分かった。また人工株式市場で起きた疑似バブルと、TOPIXに見られるバブルを比較したところ、バブル崩壊時期では似た特徴を持っていることが分かった。

本研究では実際の市場に見られる特徴として、株価変化率に関する4つの統計量に対して最適化を行ったが、今後は、他の統計量も導入することで、より複雑で実際の市場に近い変動を得ることができると考えられる。また、バブル等の特徴的な状況についても市場の分析を行い、得られた結果をもとにして人工株式市場内にもバブルが起きるように最適化を行わせることが可能になると考えられる。さらに特徴的な変動を見せる市場を構成するエージェントを解析することで、経済現象が起きる要因を探ることができると考えられる。

参 考 文 献

- 1) 和泉 潔, 植田一博: 人工市場入門, 人工知能学会誌, Vol.15, No.6, pp.941-950 (2000).
- 2) Arthur, W.B., Holland, J.H., LeBaron, B., Palmer, R. and Tayler, P.: Asset Pricing Under Endogenous Expectations in an Artificial Stock Market, *Santa Fe Institute working paper*, 96-12-093 (1996).
- 3) Joahi, S. and Bedau, M.A.: An Explanation of Generic Behavior in an Evolving Financial Market, *Santa Fe Institute working paper*, 98-12-114 (1998).
- 4) Joshi, S., Parker, J. and Bedau, M.A.: Technical Trading Creates a Prisoner's Dilemma: Results from an Agent-Based Model, *Santa Fe Institute working paper*, 98-12-115 (1998).
- 5) Schulenburg, S. and Ross, P.: An Evolutionary Approach to Modelling the Behaviours of Financial Traders, *Proc. Genetic and Evolutionary Computation Conference*, pp.245-253 (1999).
- 6) 倉橋節也, 南 潮, 寺野隆雄: 逆シミュレーション手法による人工社会モデルの分析, 計測自動制御学会論文集, Vol.35, No.11, pp.1454-1461 (1999).
- 7) Chen, S.-H. and Yeh, C.-H.: Using Genetic Programming to Model Volatility in Financial Time Series, *Genetic Programming 1997*, pp.58-63 (1997).
- 8) Iba, H.: Bagging, Boosting, and Bloating in Genetic Programming, *Proc. Genetic and Evolutionary Computation Conference*, pp.1053-

1060 (1999).

- 9) Chen, S.-H. and Kuo, T.-W.: Towards an Agent-Based Foundation of Financial Econometrics: An Approach Based on Genetic-Programming Artificial Markets, *Proc. Genetic and Evolutionary Computation Conference*, pp.966-973 (1999).
- 10) Poli, R. and Langdon, W.: On the Search Properties of Different Crossover Operators in Genetic Programming, *Genetic Programming 1998*, pp.293-301 (1998).
- 11) 佐藤 浩, 小野 功, 小林重信: 遺伝的アルゴリズムにおける世代交代モデルの提案と評価, 人工知能学会誌, Vol.12, No.5, pp.734-744 (1997).
(平成 13 年 1 月 29 日受付)
(平成 14 年 4 月 16 日採録)



山根 裕明

1975 年生。1998 年東京工業大学工学部情報工学科卒業。2000 年同大学大学院総合理工学研究科物理情報工学専攻修士課程修了。同年、松下電器産業(株)入社。現在、音楽情報処理に関する研究に従事。電子情報通信学会会員。



原 章 (正会員)

1974 年生。1997 年東京工業大学工学部電気・電子工学科卒業。1999 年同大学大学院総合理工学研究科物理情報工学専攻修士課程修了。2002 年同大学院同研究科物理情報システム創造専攻博士後期課程修了。同年広島市立大学情報科学部助手、現在に至る。博士(工学)。進化的計算法、マルチエージェント等に関する研究に従事。



長尾 智晴 (正会員)

1959 年生。1985 年東京工業大学大学院博士後期課程中退。同年同大学工学部附属像情報工学研究施設助手。1995 年同助教授。2001 年横浜国立大学大学院環境情報研究院教授、現在に至る。工学博士。画像工学、進化的計算法、神経回路網、マルチエージェント、進化経済学等に関する研究に従事。電子情報通信学会、人工知能学会、計測自動制御学会、進化経済学会、映像情報メディア学会、IEEE 等会員。