

カオス成分を考慮したマルチエージェント型人工株式市場の解析と構築

荻野 慎太郎[†] 原 章^{††} 長尾 智晴^{†††}

本研究では長期記憶性の面から、よりリアルな人工市場の構築について考察する。投資エージェントによって構成される人工株式市場が現実の市場に似た変動をするとき、市場を構成する投資戦略とその構成比がどのようなものになっているかを検証し、現実の市場における株価変動メカニズムを解析することを目的としている。市場を構成するエージェント群の戦略を木構造プログラムで表し、それらのエージェント取引によって生じる株価変動の統計量が実際の市場変動に類似するようにエージェント群の効率的な最適化と解析を行うため、先に筆者らが提案した進化の過程でエージェントのグループ分けと各グループのプログラム最適化を同時に行う手法である自動グループ構成手法 ADG を用いた。現実市場の複雑でカオティックな動態が、提案された人工市場において現れているかを、より確からしい市場構築をするという観点から実験的に示し、その解析結果を基にカオス成分を加味してより現実に即した人工市場構築を行った。

An Analysis and Construction Considering Chaotic Components of Multi-agent Based Artificial Stock Markets

SHINTARO OGINO,[†] AKIRA HARA^{††} and TOMOHARU NAGAO^{†††}

In this study we consider realistic settings of an artificial market from a viewpoint of long-memory process. With the aim of analyzing the mechanism of the stock price change, we construct an artificial stock market composed of multiple 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. In order to perform an efficient optimization and to analyze agents’ behavior easily, we use ADG; Automatically Defined Groups previously proposed by the authors. We show experimentally that complex changes and chaotic dynamics like real market appears in the proposed artificial market. It is purpose to establish more realistic settings. We constructed more realistic artificial market considering chaotic components.

1. はじめに

近年カオス解析は非線形力学システムを扱う理論として知られ、金融時系列解析などにも応用されることが多くなっている。一方、従来株式市場モデルの基礎になっている効率的市場仮説モデルでは投資家の価格予測に対し合理的期待仮説という強力な仮定をしており、最近の研究で知られるような複雑な変動を説明

することは困難である¹⁾。これに対して計算機内取引に関する戦略を持った仮想エージェントを作り、これらのエージェント群に自律的に株式取引を行わせる人工株式市場モデルの研究が行われている²⁾⁻⁶⁾。これら多くのモデルにおいて各エージェントは、過去の変動データから戦略を学習し、各々が異なった戦略を持って取引を行っている。このモデル化は、好調な経済状況を想定して利子と配当を考慮に入れた予測を行っていることや、エージェントの行動評価は行いが、取引行動の結果として得られる株価変動の評価を行っているものは少ないことなどの課題をかかえている。本研究では研究アプローチとして人工市場における株価変動が実際の市場変動に似た動きを見せるとき、市場に存在するエージェント群はどのような振舞いをしているかといった逆問題的アプローチでマイクロ-マクロ問題を解析する。現在までに筆者らの研究グループが行ったものとして文献 7), 8) では、各エージェントのとり

[†] 横浜国立大学大学院環境情報学府情報メディア環境学専攻
Department of Information Media and Environment,
Graduate School of Environment and Information Sciences,
Yokohama National University

^{††} 広島市立大学情報科学部知能情報システム工学科
Department of Intelligent Systems, Faculty of Information
Sciences, Hiroshima City University

^{†††} 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

戦略を遺伝的プログラミング (Genetic Programming; GP)⁹⁾ の個体で表現することによって人が実際に取引行動をするよりも大きな自由度を与え、これらのエージェント群からなる人工株式市場を構築した。最適化手法として個々のエージェントの取引行動を進化させるのではなく、エージェント群の株式売買によって得られる株価変動の統計量が現実の市場における変動特徴に類似するようにエージェント群全体の取引行動の最適化を行った。すなわち、GP の適用においては、GP の 1 個体が 1 つの市場を表すとした。その後、この結果をふまえ実際の市場に近似するための統計量を追加し、エージェント群の行動プログラムの最適化や行動解析に有効な改良型 GP の適用によって、その市場内に形成されたエージェント群の相互作用を解析するといった改良を先に提案した。一般に市場には多種多様な投資家が存在するが、GP を用いて各自のプログラムが異なるような不均質なエージェント集団を生成する場合、エージェント数が多いと探索領域が膨大になり、最適化が困難になる。この問題を自動グループ構成手法 (Automatically Defined Groups; ADG)^{10),11)} を用いて最適化を行った。これによってエージェントグループの相互作用という観点から株価大変動の役割を担うエージェントなどの解析を行った¹²⁾。一方、経済時系列分析など経済物理アプローチに代表されるものにおいて、現実の市場がどのような振舞いをしているかといった研究が広く行われている¹³⁾。その 1 つに Takens の埋め込み定理¹⁴⁾ を適用し、時系列データの再構成を行ってランダムだと思われていた事象がカオティックな動態を示すといった多くの研究がなされている。人工市場を構築する際にどのような評価値を適用して構築するかが焦点になるが、現在まで時系列のカオティックな動態に着目した例は少ない。そこで本研究では、エージェント群の相互作用によって獲得された変動をカオス解析することによりその事象がどのような動態を示しているのか考察する。現実的な株価変動をみせる市場を構築するために設定した適応度の評価値が十分なものであるか、主に長期記憶性の観点から現実の市場との比較を行い、ミクロ-マクロ問題解析におけるより現実らしい人工市場の再現という観点から市場の解析・構築を行う。

2. 本研究の人工株式市場設定

2.1 GP を用いた戦略形成

株価変動、あるいは市場を構成する投資家の戦略を GP の木構造を用いて表現する研究はこれまでも報告されている^{15),16)}。これらの研究では、GP の非終

端記号に用いた三角関数に株価を代入するなどして複雑な戦略表現を可能にしているが、木の解析が困難になっていることが多い。本研究では市場の解析を行いやすいように、単一の株を扱い、また扱うデータは株価変化率とする。株価変化率とは、時刻 t における株価 $Price(t)$ を用いて

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

と計算される。なお、本論文で扱う株価変動は日次データであるとする。

各エージェント i は自分の持つ予測木から予測変化率 $c_i(t)$ を獲得し、 $c_i(t)$ と現在の株価 $Price(t)$ から、明日の予測株価 $p_i(t+1)$ を以下の式に従って計算して市場に提示する。

$$p_i(t+1) = (1.0 + c_i(t)) * Price(t) \quad (2)$$

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。

2.2 市場の構成

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、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 個とする。すなわち、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 通りである。
- エージェント i は、過去の変動を利用した予測木から予測変化率を計算し、それに基づいて予測価格 (p_i) を決定して市場に提示する。
- エージェント i は
 - 株を持っている場合、株が p_i 円以上ならば売る
 - 株を持っていない場合、株が p_i 円以下ならば買う
 という取引行動をとることとする。
- 市場では、その日のすべてのエージェントの売り注文と買い注文を突き合わせて売買契約を成立させる。買い手側は高い希望価格を提示したエージェントから、売り手側は安い希望価格を提示したエージェントから優先的に取引に参加する。買い手側の希望価格が売り手側の希望価格を上回る、あるいは一致したときのみ取引が成立する。そして市場価格は、最後に成立した売買の組の希望価格の平均値として決まる。この方法は、一般的には板寄せ方式と呼ばれるもので、市場価格は最大の取引数量が実現される価格、すなわち需給が

一致する均衡価格となる。

この市場を一定期間取引させることによって、株価の変動を獲得する。

2.3 最適化に関する問題点

実際の市場を構成する投資家の予測戦略は様々である。人工市場を構成するエージェント群についても、均質なモデルではなく、同一の状況下でも各自が異なる戦略をとることが可能であるようなモデル化が必要とされる。GP を用いて各自が別々のプログラムを持つような不均質なエージェント集団を生成しようとすると、GP の 1 個体がエージェントの数だけ木構造を保持する必要がある¹⁷⁾。そのため、環境内のエージェント数が増加すると、それに応じて木構造の探索領域が膨大になり、GP による最適化が困難になる。

このように不均質なエージェント群のモデル化が必要とされる一方で、1 人 1 人のエージェントの戦略がすべて異なり、同じ戦略をとる者がまったく存在しないとは考え難い。過去のトレンドが今後も続くか予測する順張りエージェントや、これまでのトレンドと逆の方向へ株価が動くか予測する逆張りエージェント、過去の変動に関係なくランダムに予測をするエージェントなど、予測戦略のタイプは大きくいくつかに分けられると考えられ、それらをタイプごとに一括して最適化できれば、探索領域の増大を抑えることができ効率的である。この場合、GP の 1 個体が市場の再現に必要なだけの複数の戦略木を持ち、各々の木は複数のエージェントにより参照される形となる。ただし、このようなモデル化を行うには、いくつかの戦略を用意し、どのようにエージェントを配分するかをあらかじめ決める必要があり、実際の適用は困難である。

この解決策として、本研究では自動グループ構成手法 ADG¹⁰⁾ を用いて最適化を行う。この手法は、進化の過程で、問題解決に適したエージェント群のグループ分けと各グループのプログラムを同時に獲得する手法である。エージェントのグループ化により、探索領域を抑えて効率的に探索することができる。また、得られた GP 個体のグループ構造から、問題解決にはいくつかのグループによる分業が必要か、どのエージェントが同じプログラムを参照しているかが判断でき、解析が容易になるという利点がある。この手法を用いることによって、実際の市場に近い変動を見せる人工市場が獲得できたとすれば、そのときの GP 個体を調べることによって、人工市場内の戦略タイプ分類とその構成比を解析することが可能である。




図 1 現実市場の株価変動 (TOPIX: '88~'93)

Fig. 1 Time series of stock price in TOPIX (TOPIX: '88~'93).

表 1 株価変化率に関するパラメータ (その 1)

Table 1 Statistics on stock price change rates (Part 1).

パラメータ	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
Prob $\{ x < \sigma\}$	0.683	0.75 ~ 0.8
Prob $\{ x > 3\sigma\}$	0.003	0.01 ~ 0.02

2.4 人工株式市場の構築

2.4.1 人工市場の評価方法

本研究では現実市場として TOPIX 終値 1988 年 ~ 1993 年の日足である 1,024 日間の系列を採用する。この市場の株価変動を図 1 に示す。

多数の研究結果と独自の専門家への聞き取り調査から株式市場の株価変化率について、表 1 のような特徴があることが知られている^{7),13),18),19)}。

つまり、株価変化率自体についてほとんど相関性は見られないが、その変化率を二乗して得られる変動幅に関する時系列についてはかなり高い相関性が見られる。このことは、株価には、激しい変動の後には激しい変動が、小さな変動の後には小さな変動が続く傾向があることを表している。また、株価変化率の標準偏差 σ を用いて、株価変化率の絶対値が σ より小さくなる確率、 3σ より大きくなる確率を調べると、ともに正規分布よりも高い値をとる。この分布を詳しく見るため、実際の市場図 1 における変化率を平均 0.0、標準偏差 1.0 に正規化した基準化変化率のヒストグラム、および標準正規分布のグラフを描いたものを図 2 に示す。この図からも分かるように、正規分布と比較すると、高い頂点、厚い裾野を持つことが分かる。

また、式 (1) で定義した変化率に関して、過去の実際の株価変動の統計量を調べたところ、表 2 の結果を得た。平均値に比べて標準偏差が大きいこと、また、著しい周期性を持たないことが分かる。

そこで本研究では、まず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




図 2 基準化変化率のヒストグラム (TOPIX: '88 ~ '93)
Fig. 2 Histogram of normalized change rates (TOPIX: '88 ~ '93).

表 2 株価変化率に関するパラメータ (その 2)

Table 2 Statistics on stock price change rates (Part 2).

パラメータ	実際の市場
変化率の平均	-0.0003 ~ 0.0003
変化率の標準偏差	0.010 ~ 0.015
最大パワースペクトル	0.001 以下

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図 1 から観測された表 1, 表 2 の実際の市場のパラメータの条件を満たすことを目標に最適化を行う。

統計量を最適化基準とするのは株式市場はある種の確率過程であると仮定していること, 株価時系列自体の平均誤差をとると初期値の変化によって波形を再現することが難しくなると考えられるからである。さらに逆問題アプローチにおける目的の 1 つに内部エージェントの解析がある。その内部エージェントの行動規則を自動獲得し, 解析するために統計量を最適化基準として市場構築を行う。以上から各市場について表 1, 表 2 に示したパラメータを計算し実際の市場との二乗誤差の重み付け線形和をとったものを適応度とする。この誤差を小さくすることで, 現実の市場の条件を満たす人工市場の構築を行う。

この設定で構築された人工市場と現実市場を R/S 解析し, 比較・検討を行う。

2.4.2 GP の終端・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。終端記号 RND ではランダムな予測をすることとし, 正規分布に従った乱数を返す。今回の実験では, 平均 0.0, 標準偏差 0.05 の正規分布を用いた。ただし, 市場内に存在するランダム予測を同じものとして扱い市場の解析を行いやすくするため, 過去の変動とは無関係の記号である RND に対しては, rev, *2, /2 操作は行わないこととする。また終端記号 if>big-change における C_{th} には, 実際の市場の株価変化率の標準偏差の 2 倍にあたる 0.02 を用いた。

表 3 人工株式市場における終端・非終端記号設定
($arg0, arg1, \dots$ は非終端記号の引数を表す)

Table 3 GP Functions and Terminals ($arg0, arg1, \dots$ represent arguments).

記号	引数	機能
if>	4	if ($arg0 > arg1$) return $arg2$ else $arg3$
if>big-change	2	if ($ CHG > C_{th}$) return $arg0$ else $arg1$
rev	1	$-arg0$
*2	1	$2 \times arg0$
/2	1	$arg0/2$
CHG	0	前日からの変化率
RND	0	正規分布に従う乱数
ZERO	0	0

3. 構築された市場の評価

3.1 既存の市場モデルとの差異

現実市場の解析ではつねに市場合理性のもとに解析が行われてきた。しかし現実市場は合理的に効率的につまり正規分布に従うとはいえない。この点でレヴィ分布を評価基準にするとといった方法は統計的に説得力のあるモデルであるといえる。しかし現実の市場には記憶性などの要素が含まれている²⁰⁾ のではないかとの観点から, 統計量を適応度の評価値として獲得した市場における株価時系列の

- 自己相関
- 埋め込みによる再構成軌道の観測
- R/S 解析による長期記憶性

の 3 点から現実市場との比較を行う。

3.2 R/S 解析

上記の設定で構築された人工市場をカオス性の観点から評価する。カオス成分の 1 つとしてあげられる長期記憶特性の特徴量であるハースト指数を導入するために R/S 解析を行う。長期記憶性ハースト指数 H は一種のフラクタル次元で, フラクタル次元 D とは $D = 2 - H$ と関連づけられ, 複雑さの指標として用いられる。ハースト指数は $0 \leq H \leq 1$ を満たし, $H = 1/2$ の場合記憶効果のないブラウン運動に対応する。また $H = 1$ の場合, 過去の影響が現在に及び記憶効果を持つ。一般に $1/2 < H \leq 1$ であれば, 遠い過去からの記憶効果を持つと考えられる。したがって, ハースト指数は記憶という観点から時系列の構造をとらえることが可能な指標といえる²¹⁾。以下にハースト指数推定方法を示す。

$x_j(i)$ を始点 j から始まる i 番目のデータ $x_j(i) = x_{j+i-1}$ とする (x は任意の時系列)。平均値を

$$\langle x_j \rangle_\tau = \frac{1}{\tau} \sum_{i=1}^{\tau} x_j(i) \quad (3)$$

と定義し、以下の2つの統計量を算出する。

$$S(\tau) = \max_{1 \leq k \leq \tau} \sum_{i=1}^k (x_j(i) - \langle x_j \rangle_\tau) - \min_{1 \leq k \leq \tau} \sum_{i=1}^k (x_j(i) - \langle x_j \rangle_\tau)$$

$$V(\tau) = \left(\frac{1}{\tau} \sum_{i=1}^{\tau} (x_j(i) - \langle x_j \rangle_\tau)^2 \right)^{\frac{1}{2}} \quad (4)$$

具体的な計算手順としては、まず区間 τ を決めておき、始点を変化させて平均値 $\langle x_j \rangle_\tau$ を作成する。 $x_j(i) - \langle x_j \rangle_\tau$ を $i = 1$ から $i = k$ まで足し合わせる。 k を1から τ まで変化させ、その和の最大値と最小値の差を計算すると $S(\tau)$ が与えられる。また $V(\tau)$ は標準偏差である。 $S(\tau)$ は平均値からの離れ具合の大きさを示し、 $S(\tau)$ と $V(\tau)$ の比

$$R(\tau) = \frac{S(\tau)}{V(\tau)} \quad (5)$$

を算出し、

$$R(\tau) = \left(\frac{\tau}{2} \right)^{H_H} \quad (6)$$

を満たすとき、指数として得られた値 H_H をハースト数 H の推定値とする。

3.3 多次元空間への埋め込み

得られる経済時系列データは、1次元の系列であることが多い。*Takens* は1変数の時系列が分かれば系全体の挙動が再現できることを示した¹⁴⁾。具体的には変数 x 系列の各データ x_k から一定の時間遅れ τ 、 2τ 離れたデータという手順で埋め込みたい次元の数 (m 個) を取り出す。取り出したいデータを m 次元ベクトルと考えて、 m 次元空間上に1点プロットする。これを続けて m 次元空間上に、 m 次元ベクトルをプロットする。すなわち、 m 次元に系列を埋め込む場合、

$$X_1 = (x_1, x_{1+\tau}, x_{1+2\tau}, \dots, x_{1+(m-1)\tau})$$

$$X_2 = (x_2, x_{2+\tau}, x_{2+2\tau}, \dots, x_{2+(m-1)\tau})$$

$$\vdots$$

$$X_N = (x_N, x_{N+\tau}, x_{N+2\tau}, \dots, x_{N+(m-1)\tau}) \quad (7)$$

という N 個のベクトルを m 次元空間にプロットしたとき、系列 X_1, X_2, \dots, X_n はその系列を生み出す力学系のアトラクタを埋め込まれた空間へ投影し再現していることが示される。この埋め込みの操作によ

表4 市場およびGPのパラメータ
Table 4 Market and GP parameters.

エージェント数	20
株の数	10
取引期間	1,024
GP 個体数	300
選択	トーナメント +エリート保存
トーナメントサイズ	5
交叉率	0.9
突然変異率 (突然変異が適用される個体の割合)	0.9
グループ突然変異率	0.05




図3 人工株式市場の株価の推移
Fig. 3 Time series of stock price in an artificial market.

て埋め込まれた1次元の系列がランダムであるか否かが幾何学的に判別される。ブラウン運動などのランダム系列を埋め込んだ場合、点(ベクトル)は空間に一樣に広がることになる。本研究では構築された市場がどのような動態を示しているかを視覚的にとらえるため、3次元に埋め込みを行いその動態を調べる。

4. 実験結果 1

4.1 獲得された人工市場と現実市場の記憶性

既知の統計量で構築した市場およびGPのパラメータを表4に示す。このような設定で、ADGを用いてGP 個体集団を進化させた結果、表1、表2に示した市場パラメータを満たすように最適化された人工市場が得られた。シミュレーション試行数60のうち評価値が高いもの、およびグループ構造において文献12)と同じ3グループの市場を採用した。この市場における株価の例を図3に、このときの株価変化率、および二乗変化率の時系列を図4、図5にそれぞれ示す。

この人工市場の株価時系列における統計量は表5のようになっている。現実の株価変動が示す統計量と同様の値を示していることが分かる。また、図5を見ると部分的に大きな変動が続いたり、小さな変動が続いたりする期間が存在し、現実市場と同様な統計的特徴が再現されていることが分かる。




図 4 人工株式市場の株価変化率の推移

Fig. 4 Price change rates in an artificial market.




図 5 人工株式市場の二乗変化率の推移

Fig. 5 Squares of price change rates in an artificial market.

表 5 人工市場の株価変化率に関する統計量

Table 5 Statistics on stock price change rates in an artificial market.

パラメータ	人工市場
自己相関	0.10
分散の自己相関	0.41
$\text{Prob}\{ x < \sigma\}$	0.78
$\text{Prob}\{ x > 3\sigma\}$	0.019
変化率の平均	0.0003
変化率の標準偏差	0.010
最大パワースペクトル	0.0003

auto-correlation




図 6 現実市場 (TOPIX) の自己相関関数

Fig. 6 Auto-correlation function in a real market (topix).

さて、このように構築された人工株式市場の自己相関関数と 3 次元への埋め込みを行った様子を見てみる。現実市場 (TOPIX) と構築した人工株式市場の自己相関関数を図 6 と図 7 にそれぞれ示す。両者の間に目

auto-correlation




図 7 人工株式市場の自己相関関数

Fig. 7 Auto-correlation function in an artificial market.




図 8 現実市場 (TOPIX) の 3 次元への埋め込み

Fig. 8 Embedding 3rd dimension of a real market (topix).




図 9 人工株式市場の 3 次元への埋め込み

Fig. 9 Embedding 3rd dimension of an artificial market.

立った差異は認められない。これは変化率の自己相関が適応度に導入されているためであると考えられる。現実市場と人工市場の 3 次元空間への埋め込みを行ったグラフを図 8 と図 9 にそれぞれ示す。図 8 からはアトラクタらしき軌跡が見てとれるが、図 9 については統計的に似ているにもかかわらずアトラクタらしき軌道が観測されない。ブラウン運動のように空間全体に発散しているわけではないので力学系が認められるが、これを見る限り再現性はまだ低いといえる。現実市場と人工市場の記憶性の差異を図 10 に示す。この




図 10 現実市場 (TOPIX) と人工市場 (MARKET1) のハースト指数

Fig. 10 Hurst exponents in a real market and an artificial market.

期間の現実市場 (TOPIX) の方はやや強い記憶性が認められ、これは過去が現在に強く影響を与えることを示している。一方、人工市場 (MARKET1) の波形は $H = 0.65$ からなだらかに下降しており、記憶効果のない標準ブラウン運動まではいかないが記憶過程としては弱く、現実市場に似た市場が形成されているとはいえない。

図 3 と表 5 を見る限り、統計量的には現実市場と比較的変わらない市場が構築することができたと考えられる。しかし図 10 で示した長期記憶性という面で実際の市場を再現するには不十分である。そこで 5 章において市場最適化の評価という面で長期記憶性を評価関数に加えた人工市場を構築しその変動・内部エージェントの行動解析を行う。

5. 記憶性を考慮した人工市場の構築

5.1 構築設定

4 章において表 1, 表 2 で示した現実の市場より観測された株価変化率に関するパラメータを適応度として人工市場を構築・解析を行い、獲得された株価変動の長期記憶性と構造について再現性が低いといった結果を得た。これは Peters²⁰⁾ が行ったスクランブルテストによる「ある種の確率過程においてその系列の順序が記憶性を示す」という結果と同様であるといえる。この実験は記憶性が観測された時系列を混ぜ合わせる前と後の系列でハースト指数を測定したところ混ぜ合わせ後の系列では $H = 0.5$ に近づくという結論を得た。つまり元の時系列の記憶性が混ぜ合わせによって破壊されたことを示している。このことから確率過程においてその系列の順序を再現することが人工市場の構築精度を高めるのに必要であるといえる。

したがって解析から得られた結果をもとに、より精




図 11 各世代における平均グループ数

Fig. 11 Average number of groups in each generations.

度の高い市場構築をするため、表 1, 表 2 に示される株価変化率に関する統計量、長期記憶性を再現するため図 10 に示される現実市場 (TOPIX) のハースト指数の波形をこの期間における長期記憶性の値として市場最適化における GP1 個体に対する適応度として採用し再度人工市場を構築・評価を行う。長期記憶性についてはハースト指数の波形に対する二乗誤差の重み付け線形和をとる。これはハースト指数の時間における減衰曲線 (記憶が失われる過程) を再現するという観点から波形自体を最適化基準とした。波形全体にフィッティングを行うと一定の割合で推移する部分の影響が大きくなり十分な評価ができないので、前半 100 期間の波形に対して行った。

5.2 実験結果 2

ここでは記憶性を考慮して構築した人工市場に関する解析結果および考察を述べる。また、内部エージェントとその相互作用から獲得された価格変動に対して追加分析を行った結果を示す。

5.2.1 記憶性を考慮した人工市場とその動態

このような設定のもとで表 1, 表 2 および図 10 におけるハースト指数 100 期間を満たすように最適化された人工市場が得られた。60 試行のシミュレーションを行い、試行によってグループ構造はほぼ同様になったことから評価値が高いもの、およびグループ数が収束したものを採用した。各世代の平均グループ数について図 11 に示す。

この市場における株価推移の例を図 12 に、このときの株価変化率および二乗変化率を図 13, 図 14 にそれぞれ示す。

この人工株式市場の統計量は表 6 のようになっており、現実市場の変動が示す統計量である表 1 と表 2 を満たしている。図 14 が示すように部分的に変動の大小があり現実市場と同じような変動が現れていることが分かる。図 15 の自己相関関数も図 6, 図 7 と比べてもその変動が似たものであることが見てとれる。図 8,




図 12 長期記憶性を考慮した人工株式市場の株価の推移

Fig. 12 Time series of stock price in an artificial market considering long-memory process.




図 13 長期記憶性を考慮した人工株式市場の株価変化率の推移

Fig. 13 Price change rates in an artificial market considering long-memory process.




図 14 長期記憶性を考慮した人工株式市場の二乗変化率の推移

Fig. 14 Squares of price change rates in an artificial market considering long-memory process.

図 9 と同様に構築された人工株式市場の株価変動を 3 次元空間に埋め込みを行ったものを図 16 に示す．特徴的なのは図 8 と図 16 の動態が円を描きながらその円周上に 5 つほどの特徴が見られることである．この 2 つは図 9 に比べてかなり似たアトラクタが存在していると思われる．ここから現実市場と長期記憶性を考慮した人工株式市場の動態に関してその構造に相関があると判断できる．現実市場 (TOPIX), 人工株式市場市場 (MARKET1) そして長期記憶性を考慮して構築した人工株式市場 (MARKET2) のハースト指

表 6 長期記憶性を考慮した人工市場の株価変化率に関する統計量
Table 6 Statistics on stock price changes in an artificial market considering long-memory process.

パラメータ	人工市場
自己相関	0.06
分散の自己相関	0.40
$\text{Prob}\{ x < \sigma\}$	0.76
$\text{Prob}\{ x > 3\sigma\}$	0.019
変化率の平均	0.0003
変化率の標準偏差	0.010
最大パワースペクトル	0.0003

auto-correlation




図 15 長期記憶性を考慮した人工株式市場の自己相関関数

Fig. 15 Auto-correlation function in an artificial market considering long-memory process.




図 16 長期記憶性を考慮した人工株式市場の 3 次元への埋め込み

Fig. 16 Embedding dimension 3rd of an artificial market considering long-memory process.

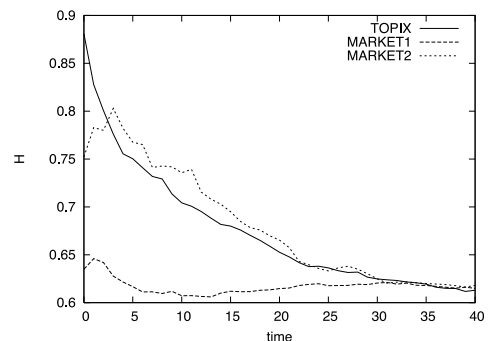


図 17 各市場のハースト指数

Fig. 17 Hurst exponents in each markets.

数に関する比較を図 17 に示す。MARKET1 に対して MARKET2 のハースト指数は現実市場 (TOPIX) に近く、図 12 の株価変動に近い記憶性が含まれていることを示している。

5.2.2 内部エージェントの行動解析と価格変動

長期記憶性の再現度が高い人工市場におけるエージェント群の構造を解析したところ、図 11 に示すようにエージェントグループ数が平均 2 グループに収束する構造が得られた。しかし木構造を解析すると、2 つの木構造にほとんど差異は見られなかったことから、すべてのエージェントが 1 つのグループにまとまった構造を持っていると考えられる。

このプログラムを解析したところ、次のような行動をとっていた。

($|CHG|$ は前日の変化率)

- (1) $|CHG|$ が大きく + : 68% で順張り, 32% で逆張りを選択
- (2) $|CHG|$ が大きく - : 47% で順張り, 53% で逆張りを選択
- (3) $|CHG|$ が小さく + : 13% で順張り, 12% で逆張り, 75% でランダムを選択
- (4) $|CHG|$ が小さく - : 12% で順張り, 88% でランダムを選択

この結果より、グループ構造としては明確な役割分担は見られなかったものの、状況に応じてエージェント群が、

- 順張り 戦略
- 逆張り 戦略
- ランダム戦略

に確率的に振り分けられているため、本質的には文献 12) と同様に 3 つの戦略の相互作用が発生していると考えられる。しかし文献 12) では各エージェントの戦略が固定であったため、売り手側や買い手側に同一の戦略エージェントが集中し取引が滞ってしまう状況が見られたが、今回得られた行動は固定化された役割分担がなく、戦略を確率的に変更できるようになったことで現実の市場のように逆張りが上昇下降のトリガになり、順張りエージェントがそれを追従するといった現実の市場参加者の特性に近づいたといえる。

次に、株価変化率について

- 高騰
- 急落

相場が上がっているときに買い, 下がっているときに売る売方のやり方
相場が下がっているときに買い, 上がっているときに買う売方のやり方

表 7 株価変化率解析 (Market 1)

Table 7 Analysis of price change rates (Market 1).

変動	発生回数	最大継続期間	平均継続期間
高騰	17	4	1.53
急落	23	4	1.22
大変動	39	4	1.38

表 8 株価変化率解析 (Market 2)

Table 8 Analysis of price change rates (Market 2).

変動	発生回数	最大継続期間	平均継続期間
高騰	44	3	1.25
急落	26	1	1.00
大変動	57	4	1.42

表 9 株価変化率解析 2 (Market 1)

Table 9 Analysis of price change rates 2 (Market 1).

変動	発生回数	最大継続期間	平均継続期間
上昇	374	5	1.37
下降	374	6	1.36

表 10 株価変化率解析 2 (Market 2)

Table 10 Analysis of price change rates 2 (Market 2).

変動	発生回数	最大継続期間	平均継続期間
上昇	202	8	2.07
下降	202	17	3.00

● 大変動

の 3 点についてそれぞれ発生回数 (連続する場合はまとめて 1 回), 最大継続期間, 平均継続期間を表 7 と表 8 に示す。この場合、株価変化率に対する閾値を 0.02 と設定した。

表 7 と表 8 においてどの変動も回数が増えておりこれは戦略を確率的に変更できるため、変動後に取引が滞ることが少なくなり市場反応がおきて価格の高騰・反落が起きやすくなっていると考えられる。

また株価変化率に対する閾値を 0.00 に、つまり変動が大きいかどうかに関係なく上昇し続ける期間、下落し続ける期間についてを表 9, 表 10 に示す。上昇・下降の継続期間が長い系列, いわばトレンドを持つ系列だということができる。表 9, 表 10 の最大継続期間, 平均継続期間ともに長期記憶性を考慮した人工市場において長くなっていることからも分かるように持続性を含む系列が獲得されている。本研究の結果から、ある種の確率過程に系列の順序つまりトレンドのある系列を含んだ構造を持つのが株式市場といえるのではないだろうか。Peters は「長期にわたる記憶はタイムスケールに関係なく生起する, 理論的に見て将来に対して影響を与える」²⁰⁾ と述べており、「埋め込み定理

は非線形な系列に対しても成立する¹⁴⁾ことから現実の市場の持続特性を人工市場に与えたことでアトラクタ構造も現実の市場が持つ特性に近づいたといえる。

6. おわりに

本研究では現実市場における株価変動の統計量に類似するようにエージェント群の取引行動を最適化し進化的に人工市場を構築した。獲得された人工市場と現実市場との類似度がどの程度なのか、カオス解析を行って比較・検討し長期記憶性の観点からより現実的な市場構築を目指した。

まず効率的に市場最適化を行う手法である ADG を用いて市場構築を行い、その結果得られた市場の株価変動をカオス解析によって評価した。その株価変動に内在する動態を観測するのに次元では限界があるので視覚的にアトラクタを観測できる三次元に埋め込みをすると同時にその系列に内在される記憶性をハースト指数を用いて比較した。自己相関関数などにおいては類似した市場であると評価できたがその構造と記憶性において現実市場と獲得された人工市場との間に差異が認められた。この差が長期記憶性の有無にあるとして、現実市場から観測された記憶性を評価値として導入した人工市場を新たに構築した。その結果、人工市場が持つ構造、長期記憶性の両面からより現実市場に近い変動を再現することに成功した。この人工市場内の価格変動と内部エージェントの取引行動の解析を行い、実際の市場参加者に似た特性が得られていることを示し、記憶性の有無が市場構築において系列構造の再現性という面で重要であることを示唆した。

エージェントベースの人工株式市場において、マイクロとしての市場に対してその株価変動の類似度の設定が重要であると考えられる。マイクロとしてのエージェントの行動解析を行うとき、その市場がどのような動態を示しているかといった情報との相互関係から行動解析が行われるので、より詳細なエージェントの行動解析が可能になる。

今後は株価にかかわらず様々な市場でその変動の統計量、構造そして長期記憶性を算出し各金融市場にあった人工市場を構築して比較・検討を行いたい。

参考文献

- 1) Shleifer, A.: *Inefficient Markets: An Introduction to Behavioral Finance*, Oxford University Press (2000).
- 2) 和泉 潔, 植田一博: 人工市場入門, 人工知能学会論文誌, Vol.15, No.6, pp.941-950 (2000).

- 3) 佐藤 浩, 久保正男, 福本力也, 廣岡康雄, 生天目章: 人工市場のシステム構造, 人工知能学会論文誌, Vol.15, No.6, pp.974-975 (2000).
- 4) Kurumatani, K., Koyama, Y., Terano, T., Kita, H., Namatame, A., Deguchi, H., Shiozawa, Y. and Matsubara, H.: U-Mart: A Virtual Stock Market as a Forum for Market Structure Analysis and Engineering, *Proc. 5th Joint Conference on Information Sciences*, pp.957-960 (2000).
- 5) 高階知巳, 渡辺成良: マルチエージェントシステムの学習過程の定量化手法—人工株式市場モデルでの評価, 計測自動制御学会論文集, Vol.35, No.12, pp.1609-1616 (1999).
- 6) 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*, pp.98-12-115 (1998).
- 7) 山根裕明, 長尾智晴: 進化的計算法を用いた人工株式市場の構築, 信学技報 [人工知能と知識処理], Vol.99, No.718, AI99-100, pp.9-16 (2000).
- 8) 山根裕明, 原 章, 長尾智晴: 株価変動の進化的最適化に基づく人工市場の構築, 情報処理学会論文誌, Vol.43, No.7, pp.2281-2292 (2002).
- 9) Koza, J.R.: *Genetic Programming: On the Programming of Computers by Means of Natural Selection*, MIT Press (1992).
- 10) 原 章, 長尾智晴: 自動グループ構成手法 ADG によるマルチエージェントの行動制御, 情報処理学会論文誌, Vol.41, No.4, pp.1063-1072 (1999).
- 11) Hara, A. and Nagao, T.: Emergence of cooperative behavior using ADG; Automatically Defined Groups, *GECCO-99: Proc. Genetic and Evolutionary Computation Conference*, pp.1039-1046, Morgan Kaufmann (1999).
- 12) Hara, A. and Nagao, T.: Construction and analysis of stock market model using ADG; Automatically Defined Groups, *The International Journal of Computational Intelligence and Applications (IJCIA)*, Vol.2, No.4, pp.433-446 (2002).
- 13) Mantegna, R.N. and Stanley, H.E.: *An Introduction to Econophysics*, Cambridge University Press (2000).
- 14) Takens, F.: Detecting Strange Attractors in Turbulence, *Dynamic System and Turbulence*, Vol.898, pp.366-381 (1980).
- 15) Iba, H.: Bagging, Boosting, and Bloating in Genetic Programming, *GECCO-99: Proc. Genetic and Evolutionary Computation Conference*, pp.1053-1060, Morgan Kaufmann (1999).
- 16) Chen, S.-H. and Kuo, T.-W.: Towards an Agent-Based Foundation of Financial Econometrics: An Approach Based on Genetic-

Programming Artificial Markets, *GECCO-99: Proc. Genetic and Evolutionary Computation Conference*, pp.966–973, Morgan Kaufmann (1999).

- 17) Luke, S. and Spector, L.: Evolving Teamwork and Coordination with Genetic Programming, *Genetic Programming 1996: Proc. 1st Annual Conference*, Koza, J.R., Goldberg, D.E., Fogel, D.B. and Riolo, R.L. (Eds.), pp.150–156, MIT Press (1996).
- 18) 佃 良彦: 金融時系列, 計測と制御, Vol.39, No.7, pp.454–460 (2000).
- 19) Izumi, K. and Ueda, K.: Phase Transition in a Foreign Exchange Market — Analysis Based on an Artificial Market Approach, *IEEE TRANS. EVOLUTIONARY COMPUTATION*, Vol.5, No.5, pp.456–470 (2001).
- 20) Peters, E.E.: *Fractal Market Analysis — Applying Chaos Theory to Investment and Economics*, John Wiley and Sons, Inc. (1994).
- 21) 松葉育雄: 非線形時系列解析, 朝倉書店 (2000).

(平成 16 年 10 月 22 日受付)

(平成 17 年 4 月 1 日採録)



荻野慎太郎

1975 年生. 国立大学法人横浜国立大学大学院環境情報学府情報メディア環境学専攻博士後期課程在籍. 進化経済学, カオス時系列解析, マルチエージェントシステム等の研究に従事. 2005 年同大学ベンチャービジネスラボラトリ講師. 現在, 事業化構想を基にしたプロジェクトの推進・研究に従事. 1999 年日本経営工学会優秀学生賞. 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. 現在, 広島市立大学情報科学部知能情報システム工学科助手. 博士 (工学). 進化的計算法, マルチエージェントシステム等に関する研究に従事. 日本知能情報ファジィ学会, IEEE, ISGEC 会員.



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. 同年同大学工学部付属像情報工学研究施設助手. 1995 年同大学工学部付属像情報工学研究施設助教授. 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. 画像処理, マルチエージェントシステム, 進化経済学に関する研究に従事. 著書『最適化アルゴリズム』(昭晃堂)等. 電子情報通信学会, 人工知能学会, 進化経済学会, IEEE 等会員.